



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

FAKULTA INFORMAČNÍCH TECHNOLOGIÍ

FACULTY OF INFORMATION TECHNOLOGY

ÚSTAV INTELIGENTNÍCH SYSTÉMŮ

DEPARTMENT OF INTELLIGENT SYSTEMS

SEGMENTÁCIA KRVNÝCH CIEV SIETNICE

RETINAL BLOOD VESSEL SEGMENTATION

BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

BARBORA NEMČEKOVÁ

VEDOUCÍ PRÁCE

SUPERVISOR

ANDRII KAVETSKYI,

BRNO 2021

Zadání bakalářské práce



Studentka: **Nemčková Barbora**
Program: Informační technologie
Název: **Segmentace krevních cév sítnice**
Retinal Blood Vessel Segmentation

Kategorie: Bioinformatika

Zadání:

1. Nastudujte techniky segmentace sítnicových krevních cév.
2. Navrhněte a implementujte vlastní algoritmus pro segmentaci krevních cév s rozdělením krevních cév do dvou skupin: tenké a silné cévy.
3. Otestujte výkon implementovaného algoritmu a určete jeho přesnost.
4. Shrňte dosažené výsledky, navrhněte možná zlepšení pro budoucí práci.

Literatura:

- J. Almotiri, K. Elleithy, and A. Elleithy. Retinal Vessels Segmentation Techniques and Algorithms: A Survey. *Applied Sciences*, 2018.
- T. A. Soomro, , A. J. Afifi, L. Zheng, S. Soomro, J. Gao, O. Hellwich, and M. Paul. Deep Learning Models for Retinal Blood Vessels Segmentation: A Review. *IEEE Access*, 2019.

Pro udělení zápočtu za první semestr je požadováno:

- Splnění bodů 1 a 2.

Podrobné závazné pokyny pro vypracování práce viz <https://www.fit.vut.cz/study/theses/>

Vedoucí práce: **Kavetskyi Andrii**

Vedoucí ústavu: Hanáček Petr, doc. Dr. Ing.

Datum zadání: 1. listopadu 2020

Datum odevzdání: 12. května 2021

Datum schválení: 11. listopadu 2020

Abstrakt

Sietnica je dôležitou súčasťou ľudského oka. Spracúva sa na nej dopadajúce svetlo a navyše, je z nej možné diagnostikovať rôzne ochorenia. Ich včasnou diagnostikou je možné predísť vážnym následkom, ako je napríklad slepota. Medzi najčastejšie ochorenia sietnice patrí diabetická retinopatia, ktorá je spôsobená cukrovkou, alebo vekom podmienená makulárna degenerácia. Automatizovaná segmentácia ciev sietnice uľahčuje a urýchľuje prácu oftalmológom. Táto práca sa zameriava na segmentáciu krvných ciev sietnice a ich následne delenie na tenké a hrubé. Navrhnutý algoritmus používa morfologické operácie, zhľukovanie metódou najbližších stredov a Frangiho algoritmus. Testovanie navrhutej metódy bolo vykonané na dátových sadách Drive a HRF. Priemerná citlivosť metódy je 69,89 %, špecifickosť 91,55 % a presnosť metódy je 88,63 %. Pri rozdeľovaní ciev sa zistilo, že v priemere 21,50 % pixelov patrí hrubým cievm a zvyšných 78,50 % tvoria tenké cievy.

Abstract

The retina is an important part of the human eye. Incident light is processed here and moreover, it plays an essential role in diagnosing various diseases. Its early diagnostics can prevent serious consequences, such as blindness. The most common retinal diseases include diabetic retinopathy, as a consequence of diabetes, and age-related macular degeneration. Automatic retinal vessels segmentation facilitates and speeds up the work of an ophthalmologist. This work focuses on retinal blood vessels segmentation and its further classification into thin and thick vessels. The proposed algorithm is based on morphological operations, k-means clustering, and Frangi's algorithm. Evaluation of the proposed method was performed on two publicly available datasets - Drive and HRF. The results obtained represent 69,89 % for sensitivity, 91,55 % for specificity, and 88,63 % for accuracy. Division of the vessels shows, that on average 21,50 % vessels pixels belong to thick vessels and the rest 78,50 % belong to thin vessels.

Kľúčové slová

segmentácia, krvné cievy, sietnica, ľudské oko, spracovanie obrazu, bioinformatika

Keywords

segmentation, blood vessels, retina, human eye, image processing, bioinformatics

Citácia

NEMČEKOVÁ, Barbora. *Segmentácia krvných ciev sietnice*. Brno, 2021. Bakalárska práca. Vysoké učení technické v Brně, Fakulta informačních technologií. Vedoucí práce Andrii Kavetskyi,

Segmentácia krvných ciev sietnice

Prehlásenie

Prehlasujem, že som túto prácu vypracovala samostatne pod vedením pána Andriiho Kavetskyiho. Uviedla som všetky literárne pramene, publikácie a ďalšie zdroje, z ktorých som čerpala.

.....
Barbora Nemčeková
10. mája 2021

Podakovanie

Ďakujem pánovi Andriimu Kavetskyimu za odborné vedenie, konzultácie, trpezlivosť a rady pri vytváraní tejto práce.

Obsah

1	Úvod	5
1.1	Ciele práce	5
1.2	Obsah práce	5
2	Ľudské oko	6
2.1	Anatómia	6
2.2	Krvné cievy	7
2.3	Fotografia očného pozadia	10
3	Analýza predchádzajúcej práce	12
3.1	Filtre	12
3.2	Matematická morfológia	16
3.3	Strojové učenie s učiteľom	17
3.4	Strojové učenie bez učiteľa	19
3.5	Sledovanie ciev	23
3.6	Segmentácia tenkých a hrubých ciev	24
4	Návrh algoritmu	25
4.1	Implementácia	25
4.2	Získanie masky	25
4.3	Predspracovanie	25
4.4	Segmentácia ciev	27
4.5	Záverečné spracovanie	28
4.6	Testovací skript	28
4.7	Aplikácia	29
5	Testovanie	30
5.1	Dátové sady	30
5.2	Meranie úspešnosti metód	31
5.3	Vyhodnotenie navrhnutých metód	31
5.4	Vyhodnotenie rozdelenia ciev	33
5.5	Experimenty	36
6	Záver	38
	Literatúra	39
A	Obsah priloženého pamäťového média	44

Zoznam obrázkov

2.1	Anatómia ľudského oka (prevzaté z [15])	8
2.2	Snímka očného pozadia: Cilioretinálna artéria vychádzajúca z okraja disku. Na začiatku (pod šípkou) utvára ostrý oblúk. Nemá napojenie na centrálnu tepnu. (prevzaté z [49])	9
2.3	Priblížená snímka očného pozadia so zameraním na kolaterálne cievy, ktoré vyzerajú ako normálne klukaté cievy. (prevzaté z [35])	9
2.4	Výšetrenie oka fundus kamerou (prevzaté z [36])	10
2.5	Optika fundus kamery (prevzaté z [3])	10
2.6	Prstencové svetlo (prevzaté z [3])	10
3.1	Obrázok v odtieňoch sivej bez filtrovania (prevzaté z [6])	14
3.2	Filtrovanie stredovou hodnotou s jadrom o veľkosti 11×11	14
3.3	Filtrovanie mediánovým filtrom s jadrom o veľkosti 11×11	14
3.4	Filtrovanie Gaussovým filtrom s jadrom o veľkosti 11×11	14
3.5	Maska v tvare disku	16
4.1	Snímka sietnice s výrazným tieňom	26
4.2	Maska oblasti záujmu pre snímku s tieňom	26
4.3	Modrý kanál	26
4.4	Zelený kanál	26
4.5	Červený kanál	26
4.6	Výsledok zhlukovania, kde $k = 3$	27
4.7	Obraz hrubých ciev	27
4.8	Manuálne segmentovaný obraz	27
4.9	Snímka obrazovky užívateľskej aplikácie - výpis nápovedy	29
4.10	Snímka obrazovky užívateľskej aplikácie - segmentované snímky	29
5.1	Segmentácia navrhnutým postupom	31
5.2	Nedetekované pixely	31
5.3	Manuálne segmentovaná snímka	31
5.4	Segmentácia navrhnutým postupom	32
5.5	Manuálne segmentovaná snímka	32
5.6	Pôvodná snímka sietnice: 22_training	33
5.7	Detekované hrubé cievy	33
5.8	Manuálne segmentovaná snímka	33
5.9	Pôvodná snímka sietnice: 40_training	34
5.10	Detegované hrubé cievy	34
5.11	Manuálne segmentovaná snímka	34
5.12	Pôvodná snímka sietnice: 08_h	35

5.13	Manuálna segmentácia	35
5.14	Detegované hrubé cievy	35
5.15	Detegované tenké cievy	35

Zoznam tabuliek

3.1	Porovnanie výsledkov testovania k-means segmentácie s rôznymi metódami predspracovania na DRIVE dátovej sade	20
3.2	Porovnanie výsledkov metód segmentácie za použitia optimalizácie rojom častíc	22
4.1	Veľkosť Gaussovho filtra pri predspracovaní pre rôzne šírky snímky	26
5.1	Vyhodnotenie segmentácie v %	32
5.2	Vyhodnotenie spracovania vybraných snímok Drive dátovej sady	34
5.3	Vyhodnotenie vybraných snímok s diabetickou retinopatiou z HRF dátovej sady	35
5.4	Vyhodnotenie vybraných snímok so zdravou sietnicou z HRF dátovej sady .	36
5.5	Vyhodnotenie vybraných snímok s glaukómom z HRF dátovej sady	36

Kapitola 1

Úvod

Oftalmológia alebo aj očné lekárstvo je medicínsky odbor, ktorý sa zameriava na vyšetrenie oka. V rámci týchto vyšetrení sa vykonáva napríklad vyšetrenie zrakovej ostrosti, meranie vnútroočného tlaku alebo aj vyšetrenie parametrov rohovky. V neposlednom rade sa vyšetruje očné pozadie, to znamená sietnica a sklovec a zrakový nerv.

Vyšetrenie sietnice je nutné najmä pri podozrení na zelený zákal, pri ochorení sietnice, sklovca alebo zrakového nervu. Pri ochorení sietnice sa vo väčšine jedná o vekom podmienenú makulárnu degeneráciu. Zo spomínaného vyšetrenia sa dá taktiež zistiť diabetická retinopatia, ktorá je vyvolaná ako komplikácia u pacientov s diabetom a taktiež makulárna diera, ktorej príčina nie je jasná.

Vyšetrenie sa vykonáva pomocou fundus fotografie, čo je proces, pri ktorom je zachytená séria snímok očného pozadia cez zrenicu. Snímky sa zachytávajú pomocou fundus kamery, ktorá je v podstate špeciálny mikroskop s nízkym výkonom a pripojenou kamerou. Očný lekár následne snímky posudzuje.

V prípade, že choroba oka nie je včasne a správne diagnostikovaná, môže nastať úplná slepota. Preto je potrebná automatická segmentácia ciev sietnice. Kvalitná segmentácia napomáha oftalmológom so skorou diagnostikou, urýchľuje prácu a môže predísť fatálnym následkom rôznych chorôb.

1.1 Ciele práce

Cieľom práce je analyzovať a popísať predchádzajúcu publikovanú prácu segmentácie krvných ciev sietnice. Na základe týchto znalostí navrhnúť a implementovať vlastný algoritmus segmentácie s rozdelením ciev do dvoch skupín, a to tenké a hrubé. Ďalším krokom je navrhnutý algoritmus otestovať a určiť jeho presnosť. Na záver je potrebné zhrnúť dosiahnuté výsledky a popísať možné zlepšenia pre budúcu prácu.

1.2 Obsah práce

Prvá časť práce, kapitola 2, sa zameriava na ľudské oko, jeho anatómiu a zloženie. Bližšie opisuje krvné cievy na sietnici a ich problematické varianty. Taktiež je tu popísaná fotografia očného pozadia. Kapitola 3 sa zameriava na vybrané techniky spracovania obrazu a opisuje analýzu predchádzajúcej práce. Návrh algoritmu a všetky použité metódy sú obsiahnuté v kapitole 4. Následne je navrhnutý algoritmus je vyhodnotený v kapitole 5.

Kapitola 2

L'udské oko

Oko je jedným z najdôležitejších zmyslových orgánov - vďaka nemu človek prijíma až 80 % informácií z vonkajšieho prostredia. Je to veľmi zložitý a dokonalý systém tvorený množstvom častí, ktoré musia dokonale spolupracovať. Z oka sa však dajú zistiť aj skryté ochorenia, ktoré sa zraku netýkajú. Diagnostikuje sa zo zrenice, dúhovky, skléry, ale aj sietnice. Tieto časti oka pomáhajú diagnostikovať napríklad vysoký krvný tlak, diabetes, vysokú hladinu cholestrolu. Ale je možné odhaliť aj skryté nádory na mozgu, rôzne druhy leukémie alebo infekčné ochorenia.

2.1 Anatómia

L'udské oko sa skladá z desiatich základných častí, viď obrázok 2.1. Každá z týchto častí hrá dôležitú úlohu pri vytváraní zrakového vnemu.

Skléra

Skléra je biela časť oka, nazývaná aj bielko, ktorá udržiava veľkosť a tvar očnej gule. Je hrubšia a pevnejšia ako rohovka a chráni oko pred poškodením. Pokrýva takmer celé oko. Tvorí ho kolagén a elastické vlákna [52].

Rohovka

Je to priehľadné a číre tkanivo, ktoré pokrýva prednú časť očnej bulvy. Základná funkcia rohovky spočíva v prepúšťaní svetla do vnútra oka a zároveň v jeho ochrane z vonkajšej strany. Rohovka je extrémne citlivá na dotyk, chemické zmeny a teplotu. Má veľa nervových zakončení. Na jej povrchu sa nachádza slzný film, ktorý chráni rohovkový epitel a kútiky oka na oboch stranách. Hrúbka kornei u dospelého človeka je okolo 1 milimetra [52].

Zrenica

Zrenica reaguje na dopadajúce svetlo a prispôsobuje sa jeho intenzite. Prispôbovanie zrenice však umožňuje dúhovka, nie samotná zrenica [52].

Dúhovka

Najdôležitejšou úlohou dúhovky je regulácia dopadajúceho svetla. V svetlom prostredí zabezpečuje, aby bola zrenica menšia a dovnútra tak prepúšťala menej svetla. Za tmy dochádza k presnému opaku: zvierač zrenice sa otvorí a zrenica sa rozšíri [52].

Šošovka

Šošovka zachytáva svetlo vstupujúce do zrenice a tým zabezpečuje ostrý obraz na sietnici. Je elastická a dokáže meniť svoj tvar pomocou ciliárneho svalu, čo umožňuje zaostrovať objekty v rôznych vzdialenostiach. Šošovka taktiež prevracia obraz a na sietnici ho vizualizuje zozadu dopredu. Obraz sa správne otáča až pri spracovaní mozgom [52].

Sklovec

Priestor medzi šošovkou a sietnicou vyplňa sklovec. Je priehľadný, z 98 % sa skladá z vody a zvyšné 2 % obsahujú kyselinu hyalurónovú a kolagénové vlákna [52].

Sietnica

Sietnica spracúva svetlo a farebné podnety a odovzdáva ich do mozgu prostredníctvom zrakového nervu. Fotoreceptory, ktoré tu ležia, sa delia na čapíky a tyčinky. Tyčinky sú citlivé na biele svetlo, naproti tomu čapíky reagujú na svetlo farebné. Funkčne najdôležitejšou časťou sietnice je jej centrum, takzvaná makula. Zodpovedá za rozkladáciu schopnosť a farebné videnie [52].

Cievnatka

Cievnatka zabezpečuje prísun živín k receptorom na sietnici, udržiava jej stálu teplotu a je zapojená aj do akomodácie (t.j. zaostrovania). Je umiestnená medzi sklérrou a sietnicou [52].

Zrakový nerv


Prenášanie informácií do mozgu zabezpečuje zrakový nerv. Vychádza zo sietnice cez miesto zvané papila. Tento bod sa označuje ako "slepá škvrna", pretože tu sietnica nemá žiadne senzorické bunky [52].

Žltá škvrna

Miestom najostrejšieho videnia je žltá škvrna, ktorá sa nachádza na sietnici. Je zložená z 3 miliónov svetlocitlivých zmyslových buniek. Uprostred nej sa nachádza centrálna jamka sietnice, ktorá umožňuje periférne videnie [52].

2.2 Krvné cievy

Sietnica ľudského oka dokáže dokonale pracovať vďaka krvným cievam. Krvné cievy majú v oku jedinečný vzor, rovnako ako odtlačky prstov. Vďaka tomu je možné oko využiť aj na identifikáciu osôb. Táto jedinečnosť však môže komplikovať vyšetrenia očného pozadia a identifikáciu chorôb.



Obr. 2.1: Anatómia ľudského oka (prevzaté z [15])

Prvé členenie vnútornej krčnej tepny je očná tepna, ktorá je prvou zo série tepien zodpovedajúcich za výživu a prekrvenie rôznych očných štruktúr a pomocných orgánov oka. Sietnica je prekrvovaná dvomi vetvami očnej tepny: centrálnou retinálnou artériou a zadnou ciliárnou artériou. Centrálna retinálna artéria sa tiahne popri optickom nerve a vstupuje do optického disku. Tu sa ďalej delí a vetví a dodáva krv do vnútorných vrstiev sietnice. Centrálna retinálna artéria je hlavným zdrojom krvi pre sietnicu.

Zadné ciliárne artérie dodávajú krv do cievnatky, ktorá vyživuje a prekrvuje vrchnú a strednú časť sietnice. Počet týchto artérií je rôzny u každého človeka, zvyčajne v rozmedzí jednej až piatich artérií. Tie sa ďalej vetvia na menšie artérie a vyživujú proximálnu cievnatku a hlavu optického nervu, prechádzajú sklérou a pokračujú v dlhých tepnách, ktoré zásobujú distálnu cievnatku [35].


Cilioretinálne tepny

Existujú rôzne anatomické varianty, ktorými sa vetví tepna zo zadných ciliárnych artérií alebo cievnatky. Tieto tepny napomáhajú centrálnej retinálnej artérii prekrvovať vnútorné časti sietnice. Štúdie ukazujú, že práve tu dochádza k najbežnejším vrodeným anomáliám vaskulatúrie sietnice, ktorá sa môže nachádzať u 6-32 % jedincov. V štúdií, ktorá používala snímky očného pozadia a fluoresceínovú angiografiu sa zistilo, že tieto subjekty mohli byť nedostatočne diagnostikované. Menej často sa môžu objaviť viaceré cilioretinálne tepny v jednom oku. Pri vývine týchto tepien hrá veľkú rolu genetika.

Cilioretinálne artérie sa klinicky javia ako cievy, ktoré vznikajú na okraji disku a klenú sa smerom von. Dôležitou vlastnosťou pri ich diagnostike je, že nemajú priame napojenie na centrálnu retinálnu tepnu a sú tvarované do ostrého oblúku. Tento jav je možné pozorovať na obrázku 2.2.

Tieto tepny zvyčajne zásobujú hlavne foveu a spodnú časť sietnice. Môžu byť tiež výhodné v prípade uzavretia centrálnej retinálnej artérie, kedy pomôžu predísť strate zraku a ďalej budú prekrvovať foveu a udržiavať cirkuláciu krvi. Rovnako aj zvýšená cirkulácia krvi môže pomôcť pri primárnom glaukóme.

Aj keď tieto cievy majú mnoho klinických benefitov, predstavujú určité riziko, napríklad uzavretie tepny. Avšak prognózy pri uzavretí tejto tepny sú väčšinou dobré a nepredstavujú riziko úplnej straty zraku. Taktiež sú spájané so zvýšeným prietokom krvi v oku, čo zvyšuje pravdepodobnosť výskytu diabetického makulárneho edému [35].




Obr. 2.2: Snímka očného pozadia: Cilioretinálna artéria vychádzajúca z okraja disku. Na začiatku (pod šípkou) utvára ostrý oblúk. Nemá napojenie na centrálnu tepnu. (prevzaté z [49])

Kolaterálne cievy

Kolaterály vznikajú na sietnici z viacerých príčin. Medzi časté príčiny patrí napríklad vaskulárna oklúzia, glaukóm, alebo diabetes mellitus a ďalšie. V súvislosti s oklúziou, teda upchaním žíl, vznikajú tieto skratky za účelom transportu krvi z cievy, kde sa nachádza prekážka. Kolaterály majú podobnú charakteristiku ako normálne cievy na sietnici, a teda, kanál, ktorý tvoria, prepája vnútorné vrstvy sietnice.

Tiež sa môže stať, že sa kolaterály vytvoria bez zdravotnej príčiny. V tom prípade nemajú žiadny klinický význam a u zdravých pacientov zostávajú nemenné.

V diagnostike býva problematické odlíšiť kolaterály od neovaskularizácie, teda rastu nových kapilár v oblasti rohovky oka. Kolaterály sa javia ako normálne kľukaté cievy, vid. obrázok 2.3, ktoré spájajú napríklad žily alebo tepny. Neovaskulárne cievy sú naopak malé a tenké. [47, 35]



Obr. 2.3: Priblížená snímka očného pozadia so zameraním na kolaterálne cievy, ktoré vyzerajú ako normálne kľukaté cievy. (prevzaté z [35])

2.3 Fotografia očného pozadia

Fotografia očného pozadia zachytáva sietnicu a neurosenzorické tkanivo v oku. Vytvára sa priamo cez zrenicu. Pacient sedí oproti kamere, s bradou položenou na opierke a čelom proti tyči. Kamera vyžaduje, aby ju lekár nastavil a zaostril. Po stlačení spúšte sa aktivuje blesk, ktorým sa vytvorí snímka očného pozadia. Toto vyšetrenie zobrazuje obrázok 2.4.


Pri vytváraní fotografie môžu byť použité rôzne farebné filtre alebo špeciálne farbivá. Medzi tieto farbivá patrí napríklad indokyanínová zeleň alebo fluoresceín [44].




Obr. 2.4: Vyšetrenie oka fundus kamerou (prevzaté z [36])

Fundus kamera

Fundus kamera je špeciálny mikroskop s pripojenou kamerou, ktorého optický dizajn bol založený na dizajne nepriameho oftalmoskopu. Kamery sa delia do kategórií na základe optického uhla, ktorý prijíma šošovka. Za základný uhol sa pokladá uhol 30° , kedy sa vytvorí 2,5-krát zväčšený obraz. Pri použití kamery s väčším uhlom, 45° až 140° , sa získa proporcionálne menšie zväčšenie sietnice. Kamery s úzkym uhlom poskytujú uhol pohľadu menší ako 20° [44].



Obr. 2.5: Optika fundus kamery (prevzaté z [3])



Obr. 2.6: Prstencové svetlo (prevzaté z [3])

Optika fundus kamery

Pomocou lampy alebo elektronického blesku je generované svetlo, ktoré prechádza rôznymi filtrami a okrúhlym zrkadlom. Toto zrkadlo odráža svetlo ďalej do série šošoviek, ktoré svetlo zameriavajú. Posledná šošovka obsahuje filter, ktorý formuje svetlo do tvaru prstenca, viď obrázok 2.6. Toto prstencovité svetlo sa odráža na okrúhlom zrkadle, ktoré obsahuje centrálnu clonu. Ďalej vystupuje z fotoaparátu cez šošovku objektívu a vstupuje do oka cez rohovku.

V prípade, že osvetľovací systém a obraz sú správne nastavené a zaostrené, výsledný obraz sietnice vychádza z rohovky cez neosvetlenú časť prstenca. Svetlo naspäť prechádza cez otvor okrúhleho zrkadla, astigmatické korekčné zariadenie a dioptrické korekčné šošovky a následne je zachytený kamerou [44]. Jednoduchý náčrt optiky fundus kamery je zobrazený na obrázku 2.5.

Kapitola 3

Analýza predchádzajúcej práce

3.1 Filtre

Filtrovanie patrí medzi základné prístupy v oblasti počítačového videnia a spracovania obrazu. Mnohé algoritmy segmentácie očných ciev zo sietnice využívajú niektorý z nasledovných filtrov.

Základom každého filtra je matica, teda jadro. Toto jadro sa aplikuje na každý pixel obrazu a vypočíta sa nová hodnota pixelu.

Filtrovanie strednou hodnotou

Filtrovanie strednou hodnotou, tzv. Mean filter, je jednoduchá metóda používaná na vyhladenie obrazu. Znižuje sa rozdiel intenzít medzi jednotlivými pixelmi a používa sa tiež na zmiernenie šumu v obraze. Zaraduje sa medzi konvolučné filtre.

Princíp tohto filtra je nahradiť hodnotu každého pixelu priemernou hodnotou v jadre, teda samotného pixelu a všetkých jeho susediacich pixelov. Zvyčajne sa používa jadro o veľkosti 3×3 , ale je možné použiť aj väčšie filtre pre väčšiu redukciu šumu.

Táto metóda sa zvyčajne používa v rámci predspracovania. Na obrázku 3.2 je zobrazené filtrovanie touto metódou s jadrom o veľkosti 11×11 .

Autori článku [38], *Temitope Mapayi, Serestina Viriri a Jules-Raymond Tapamo* zvolili predspracovanie pomocou viacerých metód a jednou z nich je práve filtrovanie strednou hodnotou.

Mediánový filter

Priemerovanie susedských pixelov môže mať nežiaduce efekty ako napríklad rozmazanie čiar a ostrých hrán.

Medianový filter je efektívna metóda, ktorá do istej miery dokáže rozlíšiť šum od obrazových prvkov, ako sú hrany a čiary. Výsledok filtrovania mediánovým filtrom je možné pozorovať na obrázku 3.3 Tento filter miesto priemernej hodnoty v jadre vyberá strednú hodnotu, teda medián. Radí sa medzi nelineárne filtre.

Táto metóda bola použitá napríklad v práci [33] ako predspracovanie pred samotnou segmentáciou a klasifikáciou pomocou neurónových sietí. Taktiež bola použitá v práci [38] ako jedna z viacerých metód predspracovania. Ako je vidieť v tabuľke 3.1, predspracovanie pomocou mediánového filtra prinieslo lepšie výsledky oproti Gaussovmu a Mean filtru,

najmä v oblasti senzitivity. Tieto práce sú bližšie analyzované v sekcii o strojovom učení s učiteľom 3.3 a bez učiteľa 3.4.

Gaussov filter

Na vyhladenie obrazu sa taktiež používa Gaussovský operátor, ktorý sa radí medzi konvolučné filtre. Využíva sa na redukciu šumu a je podobný Mean filtru. Využíva iné jadro, a to také, ktoré reprezentuje Gaussovo rozloženie.

Výsledkom pre každý pixel je vážený priemer jeho susedských pixelov, s priemerom váženým viac k hodnote stredových pixelov v matici. Vďaka tomu Gaussov filter ponúka jemnejšie vyhladenie obrazu s ohľadom na hrany. Obrázok 3.4 prešiel filtrovaním s jadrom o veľkosti 11×11 .

V článku [37] autori opisujú použitie Gaussovho filtra na segmentáciu. V rámci predspracovania je použitá metóda CLAHE a Mean filter na zredukovanie šumu, ktorý vytvára metóda CLAHE. Taktiež je použité morfológické otvorenie, aby sa odstránili objekty ako optický disk. Vďaka segmentácii Gaussovým filtrom sú vo výslednom obraze viditeľné aj tenké a nejasné cievy. Táto metóda vykázala veľmi dobré výsledky najmä v oblasti špecifickosti - 96,90 %, presnosť vyšla na 95,72 % a senzitivita na 82,10 %.

Sobelov operátor

Sobelov operátor sa využíva na detekciu hrán v obraze.

Tento operátor sa skladá z dvoch konvolučných jadier, kde jedno z jadier je otočené o 90° . Vďaka tomu je možné nájsť hrany vertikálne aj horizontálne. Pri vertikálnej maske je prostredný stĺpec nulový a vypočítava sa rozdiel pravých a ľavých pixelov v okolí hrany. Taktiež prostredné hodnoty prvého a tretieho stĺpca sú väčšie ako ostatné, a teda sa dáva väčšia váha pixelom pri pixely hrany.

V práci [28] predstavenej *Ghadiri et al.* bol využití Sobelov operátor na detekciu hrán ciev. Prechádzajúcim krokom je extrakcia smeru lineárnych štruktúr, čo uľahčuje detekciu hrán. Na rozdiel od bežného Sobelovho operátora, autori nepoužili prahovú hodnotu ale dve maximálne hodnoty v okolí lineárnej štruktúry.


Laplaceov filter

Laplaceov filter je detektor hrán, používaný na vypočítanie druhých derivácií v obraze a zistenie hodnoty, v ktorej sa prvá derivácie mení. Jadro tohto filtru zvyčajne obsahuje negatívne hodnoty na kríž stredového pixelu, nulové alebo kladné hodnoty v rohoch. Stredový pixel je záporný alebo kladný.


Prof. Dr. Chorage a Khot vo svojej práci [46] o extrakcii ciev na detekciu diabetickej retinopatie použili práve tento operátor na detekciu hrán. Najprv sa snímka predspracuje pomocou CLAHE metódy a následne sa aplikuje Laplaceov operátor. Za tým nasleduje morfológická erózia na odstránenie falošne detekovaných štruktúr. Z takto segmentovaného obrazu je podľa autorov možné detegovať blokádu krvi v cievach a s tým spojenú diabeticke retinopatiu.



Obr. 3.1: Obrázok v odtieňoch sivej bez filtrovania (prevzaté z [6])



Obr. 3.2: Filtrovanie stredovou hodnotou s jadrom o veľkosti 11×11



Obr. 3.3: Filtrovanie mediánovým filtrom s jadrom o veľkosti 11×11



Obr. 3.4: Filtrovanie Gaussovým filtrom s jadrom o veľkosti 11×11

Cannyho hranový detektor

Cannyho hranový detektor je viacúrovňový algoritmus na detekciu hrán v akomkoľvek vstupnom obraze. Algoritmus je založený na obraze v odtieňoch sivej, preto sa ako pre-rekvizita vyžaduje transformácia obrazu.

Kroky algoritmu sú nasledovné:

- Redukcia šumu pomocou Gaussovho filtra. Veľkosť filtra závisí na požadovanom rozmazaní. Čím je filter menší, tým menej bude rozmazanie viditeľné.
- Výpočet gradientov - umožňuje určiť intenzitu a smer hrán pomocou operátorov pre detekciu hrán. Najčastejšie sa využíva Sobelov operátor.
- Non-maximum Suppression - algoritmus prechádza cez všetky body v matici gradientu a nájde pixel s najvyššou hodnotou v smere hrany.

- Dvojité prahovanie - cieľom je, identifikovať 3 druhy pixelov: silné, slabé a nerelevantné. Silné pixely majú vysokú intenzitu a patria hrane. Nerelevantné pixely s určitou nie sú súčasťou hrany. Slabé body nemajú dostatočne vysokú intenzitu, aby boli považované za body hrany a zároveň nie sú dostatočne nízke, aby boli nerelevantné.
- Finálna detekcie hrán. Pixely, ktoré sú označené ako slabé sa vyhodnotia ako silné, ak sú susediace so silným pixelom. Inak sú považované za nerelevantné [43] [1].

Použitie tohto algoritmu opisujú autori článku [32] pri detekcii optického disku. Po spracovaní bol lokalizovaný optický disk pomocou filtru štandardnej odchýlky intenzity, aplikovalo sa morfologické uzavretie a následne Cannyho hranový detektor s nízkym prahom 0,4 a vysokým prahom 0,1.

Tento hranový detektor bol taktiež použitý v práci [23], kde bol najprv implementovaný Frangiho algoritmus 3.1 na rôzne veľkosti rozlíšenia, následne bol autormi navrhnutým filtrom odstránený odraz kamery na cievach. Ako posledný krok segmentácie sa použil Cannyho hranový detektor, ktorého výstupom je binárny obraz. Binárne obrazy zo všetkých rozlíšení sú na záver spojené pomocou OR operátora.

Chang et al. [24] predstavili modifikovaný hranový detektor na extrakciu malých ciev sietnice. Na rozdiel od pôvodného detektora, ktorý využíva globálne prahové hodnoty, navrhnutý algoritmus využíva lokálne prahové hodnoty, aby sa vyhol strate slabých hrán. Experimenty vykonané autormi ukázali zlepšenie segmentácie malých ciev oproti pôvodnému detektoru.

Frangiho algoritmus

Frangiho filter je prístup, ktorý umožňuje vidieť rúrkovité štruktúry, a teda aj cievy v obraze. Využíva sa n-dimenzionálna Hessova matica spojitej funkcie f , ktorá obsahuje derivácie druhého rádu. Platí:

$$\lambda_1 = \frac{1}{a^2} \quad (3.1)$$

$$\lambda_2 = \frac{1}{b^2} \quad (3.2)$$

$$\lambda_3 = \frac{1}{c^2} \quad (3.3)$$

kde a je dĺžka rúrkovitej štruktúry, b je výška a c je šírka. Na základe hodnôt λ_1 , λ_2 a λ_3 je možné definovať 3 druhy štruktúry: tanierovitý, rúrkovitý a tvar kvapky. Hodnoty, ktoré udávajú tvar štruktúry, určujú taktiež či sa jedná o svetlú alebo tmavú štruktúru. V prípade, že sú vysoké hodnoty záporné, ide o svetlú štruktúru. Naopak štruktúra je tmavá so svetlým pozadím v prípade, že výsledné vysoké hodnoty sú kladné.

V 2D obrazoch, a teda aj pri segmentácii krvných ciev sietnice, sa λ_3 a parameter c nepoužíva [27].

Definícia funkcie je:

$$V_0(s) = \begin{cases} 0 \\ \left(1 - \exp\left(\frac{-R_A^2}{2\alpha^2}\right)\right) \left(\exp\left(\frac{-R_B^2}{2\beta^2}\right)\right) \left(1 - \exp\left(\frac{-S^2}{2c^2}\right)\right) \end{cases} \quad (3.4)$$

kde S je určuje šírku ciev, ktoré bude možné nájsť. α , β a c sú konštanty, ktoré upravujú senzitivitu filtra. Pre R_A a R_B platí:

$$R_A = \frac{|\lambda_2|}{|\lambda_3|} \quad (3.5)$$

$$R_B = \frac{|\lambda_1|}{\sqrt{\lambda_2 * \lambda_3}} \quad (3.6)$$

Odporúča sa tieto výpočty opakovať pre rôzne šírky ciev, teda meniť hodnotu σ , od najmensej až po najväčšiu hodnotu očakávanej šírky.

Tento prístup bol použitý napríklad v práci *A. Budai et al.* [23], kde po predspracovaní implementovali Frangiho algoritmus. V ich práci však neopakovali výpočty pre rôzne hodnoty šírky ciev ale hodnotu σ stanovili na malú konštantu a výpočty opakovali pre rôzne rozlíšenia.

Frangiho filter spolu s Gaborovou funkciou bol opísaný v článku [40] na vylepšenie ciev. Hodnotu σ zvolili inkrementovať o 0,1 od 1 po 4. Následne na samotnú segmentáciu použili Fuzzy C-Means algoritmus.

3.2 Matematická morfológia

Matematická morfológia je technika používaná pri extrahovaní komponent obrazu, ktoré sú potrebné na opis tvaru objektu, jeho hraníc, vyplňaní dier v objekte a nájdenie kostry objektu. Morfológia sa používa najmä pri predspracovaní a záverečnom spracovaní obrazu. Aplikuje sa na binárne obrazy alebo obraz v odtieňoch sivej.

Dôležitou súčasťou morfologických operácií je štruktúrny prvok. Na spracovanie medicínskych snímok sa najčastejšie používa maska v tvare disku, ktorej príklad je možné vidieť na obrázku 3.5. Maska v tvare disku je nezávislá od otočenia, čo predstavuje veľkú výhodu oproti iným maskám [31].

```

0 0 0 0 1 0 0 0 0
0 0 1 1 1 1 1 0 0
0 1 1 1 1 1 1 1 0
0 1 1 1 1 1 1 1 0
1 1 1 1 1 1 1 1 1
0 1 1 1 1 1 1 1 0
0 1 1 1 1 1 1 1 0
0 0 1 1 1 1 1 0 0
0 0 0 0 1 0 0 0 0

```

Obr. 3.5: Maska v tvare disku

Základné morfologické operácie sú erózia a diletácia. Erózia sa používa na zjednodušenie štruktúry objektov, pričom objekty hrúbky 1 sa úplne stratia. Naopak diletácia zväčšuje objekty a používa sa k zaplneniu malých dier. Kombináciou týchto dvoch operácií vznikajú ďalšie dve významné operácie pre spracovanie obrazu - otvorenie a uzavretie. Slúžia k odstráneniu detailov v obraze ako je napríklad šum, pričom veľkosť a tvar obrazu zostávajú nezmenené. Morfologické otvorenie spočíva vo vykonaní erózie a následne diletácie a odstraňuje šum pozadia obrazu. Zatvorenie je diletácia s následnou eróziou. Táto kombinácia operácií uzatvára diery v objektoch alebo odstraňuje mierny šum vyskytujúci sa na objekte [7].

Medzi zložitejšie operácie patria napríklad top hat transformácie. Top-hat transformácia extrahuje z obrazu malé elementy a detaily. Poznáme 2 druhy: biela top-hat a čierna top-hat transformácia. Biela top-hat je definovaná ako obraz, mínus jeho morfológické otvorenie. Táto operácia vracia svetlé body, ktoré sú menšie ako štrukturálny prvok. Čierna top-hat je definovaná ako morfológické uzavretie mínus pôvodný obraz. Táto operácia vracia tmavé elementy, ktoré sú menšie ako štrukturálny prvok. Vo výslednom obraze po vykonaní čiernej top-hat transformácie sú však tieto prvky zobrazené ako svetlé [7].

Segmentáciu pomocou morfológie navrhol *Prof. Manjusha S. Borse* [21]. Skladá sa z troch krokov: 1) Predspracovanie 2) Morfológická segmentácia a vyplnenie ciev 3) Extrakcia stredovej osi ciev.

Počas segmentácie v tomto algoritme bola použitá dilatácia na zväčšenie objektov a vyplnenie dier. Erózia slúži na zmenšenie objektov. Na samotnú segmentáciu bola použitá top-hat transformácia s rôznymi štrukturálnymi elementami, napríklad v tvare gule, disku, štvorca alebo čiary. Elementy boli použité s rôznymi veľkosťami a v rôznych smeroch otočenia. Algoritmus bol otestovaný na Drive dátovej sade, s výsledkom presnosti 96,79 %.

Spracovanie obrazu pomocou morfológických operácií bolo použité v štúdií [19] na obrázky s diabetickou retinopatiou. Najprv je vstupný obraz spracovaný pomocou adaptívneho vyrovnania histogramu s obmedzeným kontrastom (CLAHE) a následne vylepšený pomocou morfológických operácií, vrátane top-hat transformácie. Posledným krokom tohto algoritmu je hysterézne prahovanie.

Na otestovanie tejto metódy boli použité dve dátové sady: HRF a DR HAGIS. Priemerná presnosť na HAGIS dátovej sade bola 95,12 % a na HRF dátovej sade to bolo o niečo menej, a to 94,38 %.

3.3 Strojové učenie s učiteľom

Učenie s učiteľom je podkategória strojového učenia a umelej inteligencie. Algoritmy učenia s učiteľom sú navrhnuté tak, aby sa vedeli učiť na príklade. Používajú tréningovú množinu vstupov a korektných výstupov na učenie modelu dosiahnuť správny výsledok. Počas tréningu algoritmy hľadajú vzory v dátach, ktoré korelujú s požadovanými výstupmi.

Učenie s učiteľom môže byť rozdelené do dvoch kategórií:

- Klasifikácia - vstupné dáta sú priradené triede alebo kategórii na základe poskytnutých tréningových dát.
- Regresia - je prediktívny štatistický proces. Snaží sa nájsť vzťahy medzi závislými a nezávislými premennými.

Konvolučné neurónové siete

Konvolučná neurónová sieť je algoritmus hlbokého učenia. Výhodou je, že vyžaduje menej predspracovania v porovnaní s inými prístupmi. Úlohou týchto sietí je zmenšiť obrázok na takú formu, aby sa ľahko spracoval bez straty vlastností.

10 vrstvová konvolučná neurónová sieť bola navrhnutá *Melinscak, Prentasica a Loncaric* [39] s použitím max-poolingu. Max-pooling vrstvy sú pevne stanovené a netréňované. Na vykonanie segmentácie sa používajú bloky s nepárnym počtom pixelov, aby sa určila trieda centrálného pixelu. Na tréňovanie sa používajú manuálne segmentované obrázky. Táto 10-vrstvová sieť sa skladá striedavo zo 4 konvolučných vrstiev a 4 max-pooling vrstiev.

Na konci sú 2 plne prepojené vrstvy. Pri testovaní mala táto metóda priemernú presnosť 94,66 %.

Plne konvolučnú neurónovú sieť navrhli autori článku [42]. Na začiatok implementovali statickú vlnkovú transformáciu aby sa využila viacúrovňová povaha vaskulatúry oka. Taktiež experimentálne prišli na to, že sieť pracuje lepšie pri používaní masiek z väčších obrázkov, ktoré extrahovali počas tréningu siete. Architektúra algoritmu sa skladá z kódera a dekódera, ktorá bolo inšpirovaná štúdiom predchádzajúcimi prácami. V samotnej neurónovej sieti použili Xavierovu inicializáciu, ako aktivačnú funkciu použili tzv. Rectified Linear Unit, ďalej max-pooling a na vzorkovanie interpoláciu najbližšieho suseda.

V klasickej konvolučnej sieti sa používa aspoň jedna plne spojená vrstva, kvôli ktorej je vstupný obraz obmedzený na jednu fixnú veľkosť. Autori tohto algoritmu navrhli zmeniť plne spojenú vrstvu za konvolučnú vrstvu s jadrom o veľkosti 1×1 . V tom prípade nie je vstupný obraz fixovaný rozmermi.

Ďalšou prácou zameranou na segmentáciu pomocou konvolučných sietí bola práca *K. Balasubramanian, N.P. Ananthamoorthy* [33], v ktorej opisujú použitie konvolučných neurónových sietí spolu s metódou podporných vektorov. Na predspracovanie bol použitý mediánový filter a na segmentáciu metóda zoskupovania super-pixelov. V tomto algoritme sa najprv zozbierajú super-pixelly zo vstupného obrazu, následne sa zostrojí dvojstranný graf, na ktorý je aplikovaná T-cut metóda na vytvorenie k skupín. Pixelly v jednej skupine sa považujú za segment. Na segmentáciu konkrétnej oblasti zo sieťnicového obrazu sa používa metóda strednej orientácie. Po segmentácii nasleduje extrakcia vlastností pomocou konvolučných neurónových sietí, ktorá pomáha s klasifikáciou krvných ciev. Dôležité aspekty, ktoré sú tu zahrnuté sú lokálna konektivita, zdieľanie parametrov a max-pooling vrstva. Po extrakcii sú vlastnosti klasifikované pomocou metódy podporných vektorov, čo je metóda učenia s učiteľom.

Testovanie na Drive dátovej sade ukázalo veľmi sľubné výsledky. 40 % snímok z dátovej sady bolo použitých na tréning a zvyšných 60 % bolo testovacích. Senzitivita navrhovanej metódy vyšla na 97,12 %, špecifickosť na 98,09 % a presnosť 97,43 %.

Algoritmus K-najbližších susedov

K-najbližších susedov, alebo aj KNN, je jednoduchý algoritmus, ktorý sa používa na riešenie klasifikačných, aj regresných problémov. Zvyčajne je založená na Euklidovskej vzdialenosti, ktorej predpis je vzorec 3.7, medzi skúšobnou vzorkou a konkrétnymi klasifikovanými vzorkami.

$$d(x, y) = \sqrt{\sum_{k=1}^n (x_k - y_k)^2} \quad (3.7)$$

S.A. Salem, N.M. Salem, a A.K. Nandi [45] navrhli algoritmus na segmentáciu ciev sieťnice založený na algoritme k-najbližších susedov. Najväčším rozdielom je, že navrhnutý algoritmus nevyžaduje trénovaciu sadu. Navrhnutý algoritmus je možné rozdeliť na dve etapy. V prvej etape sa náhodne zvolí N pixelov, z ktorých sa vytvoria neprekrývajúce sa zhľuky o maximálnej veľkosti K_{init} pixelov. Následne sa aktualizujú zhľuky a ich členstvá tak, aby vznikol predom definovaný počet zhľukov. Druhá etapa je priradiť zvyšné pixeli. Pre každý nepriradený pixel je nájdených K najbližších pixelov. Pixel je priradený do zhľuku, ktorému patrí najväčší počet nájdených K pixelov.

Autori na vyhodnotenie svojho algoritmu použili 20 snímok a výsledky porovnali s výsledkami bežného KNN algoritmu, u ktorého bolo 10 obrazov použitých na tréning a 10 na test. Navrhnutá metóda vykazovala asi o 5 % horšie výsledky oproti KNN algoritmu.

Vážený KNN algoritmus navrhli *B.J. Zou, Y. Chen, CZ. Zhu* [20] na klasifikáciu ciev na tepny a žily. Autori upravili výpočet Euklidovskej vzdialenosti o hodnotu w_k , ako ukazuje vzorec 3.8. Ak $w_1 \rightarrow +\infty$, vlastnosť 1 sa stáva rozhodujúcou. Súčasťou ich algoritmu bola, okrem iného, aj extrakcia osi ciev. Pixely patriace tejto osi sa využili pri klasifikácii a rozdeľovali sa na základe mäkkého rozhodovania. Navrhnutým algoritmom bolo však možné klasifikovať len cievy väčšie ako 2 pixely. Presnosť algoritmu bola stanovená na 88,51 %.

$$d(x, y) = \sqrt{\sum_{k=1}^n (w_k \times (x_k - y_k)^2)} \quad (3.8)$$

3.4 Strojové učenie bez učiteľa

Strojové učenie bez učiteľa je špecifické tým, že má k dispozícii len vstupné hodnoty. Na rozdiel od učenia s učiteľom nemá fázu tréningu a ani mu nie je poskytnutá dátová sada, z ktorého by mal zistiť aké výstupné hodnoty treba používať. Úlohy tohto typu analyzujú sadu objektov, ktoré nemajú priradenú triedu.

Je možné ho rozdeliť do dvoch kategórií:

- Zhhlukovanie - spracováva dáta a vytvára prirodzené skupiny.
- Asociácie - hľadá zaujímavé vzťahy medzi premennými vo veľkých databázach.

Zhlukovanie metódou najbližších stredov

Zhlukovanie metódou najbližších stredov, ďalej len k-means, je zhlučovacia algoritmus, ktorý predpokladá, že neznáme dáta, ktoré popisujú n -rozmerné vektory, tvoria v priestore k zhlučkov a každý zhluček je reprezentovaný prototypom - ťažiskom. Pri spracovaní obrazu, dáta, a teda aj vektory, tvorí histogram intenzít a ťažiská sú náhodne vybrané intenzity z vypočítaného histogramu.

Jedným z možných využití k-means algoritmu je na samotnú segmentáciu, ako opisujú autori *Gehad Hassan et al.* v článku [30]. Autori v rámci predspracovania použili morfológické operácie na vyhladenie obrazu a redukciu šumu. Najprv bol na vstupný obraz použitý operátor otvorenia a rekonštrukčný operátor na vyhladenie obrazu. Následne prešiel obraz top-hat transformáciou a bol naň aplikovaný Gaussov filter so šírkou 7 pixelov. Na takto vylepšený obraz je možné aplikovať k-means zhhlukovanie. V tomto prípade boli náhodne zvolené 2 ťažiská. Počítajú sa vzdialenosti medzi jednotlivými pixelmi a ťažiskami a pixel je priradený do triedy, ktorá mu je bližšia. Priemerná hodnota histogramu je zvolená ako nové ťažisko. Tieto kroky sa opakujú pokiaľ sa prototypy menia.

Testovanie tejto metódy prebehlo na DRIVE dátovej sade. Senzitivita metódy vyšla na 87,99 %, špecifickosť na 97,99 % a presnosť na 96,25 %. V porovnaní s inými prístupmi spomenutými v článku [30], vyšli veľmi dobré výsledky presnosti, čo dokazuje zlepšenie v oblasti nesprávnej klasifikácie.

Podobný prístup použili aj *T. Mapayi, S. Viriri a J. R. Tapamo* v ich práci [38]. Na predspracovanie vstupného obrazu použili hneď niekoľko filtrov samostatne: Gaussov, Mean a Medianový filter. Z obrazov bol extrahovaný zelený kanál. Ďalším krokom bola segmentácia pomocou k-means zhhlukovania. Segmentovali sa obrazy na ktorých bol použitý Gaussov,

Mediánový a Mean filter samostatne, ale aj ich kombinácie. Konkrétne sa jednalo o kombináciu Mediánového a Mean filtra, kombináciu Mediánového a Gaussovho filtra a kombináciu Mean a Gaussovho filtra. Zhlukovanie na základe intenzít prebehlo podobne ako je popísané v predchádzajúcom algoritme [30]. Na záver bol na každý obraz použitý Medianový filter a morfológické otvorenie na odstránenie falošne detekovaných pixelov a mediánový filter o veľkosti 2×2 na odstránenie šumu.

Tabuľka 3.1: Porovnanie výsledkov testovania k-means segmentácie s rôznymi metódami predspracovania na DRIVE dátovej sade

Metóda predspracovania	Senzitivita	Špecifickosť	Presnosť
Morfologické operácie [30]	87,99	97,99	96,25
Mediánový filter [38]	73,99	97,66	95,56
Mean filter [38]	64,59	98,55	95,55
Gaussov filter [38]	63,15	98,69	95,55
Mediánový + Mean filter [38]	75,81	97,03	95,16
Mediánový + Gaussov filter [38]	75,18	97,26	95,31
Mean + Gaussov filter [38]	70,79	97,59	95,23

Metóda vykazuje veľmi dobré výsledky najmä v oblasti špecifickosti. K-means v kombinácii s mediánovým filtrom preukázalo lepšie výsledky oproti filtru Gaussovmu a Mean filtru. Avšak ako je možné vidieť v tabuľke 3.1, všeobecne najlepšie výsledky k-means segmentácie má metóda navrhnutá *Gehad Hassan et al.*[30], kde bolo predspracovanie navrhnuté pomocou morfológických operácií.

V článku [41] autori predstavili metódu, kde v rámci predspracovania použili k-means zhlukovanie na odstránenie svetlých lézií, aby sa uľahčilo rozpoznávanie ciev a zároveň, aby základná štruktúra vstupného obrazu ostala nezmenená. Pixel v obraze môžu byť rozdelené do troch kategórií: pozadie, popredie a cievy. Pixel pozadia sú také, ktoré nepatria cievam, léziám, ani optickému disku. Sú tmavšie ako lézie a optický disk, ale svetlejšie ako cievy. Optický disk a lézie sa radia do kategórie popredia. Autori na základe strednej a štandardnej odchýlky matice intenzít určili počiatočné prototypy zhlukov. Pixel sa priradia do zhlukov a vypočítajú sa nové prototypy. Algoritmus sa opakuje kým sa zhluky a prototypy neustália. Po procese zhlukovania sa použije ťažisko popredia na odstránenie svetlých lézií.

$$df_p = c_f - I_p \quad (3.9)$$

I_p je intenzita pixelu p , c_f je hodnota ťažiska popredia, a teda df_p je rozdiel intenzity pixelu od intenzity prototypu popredia. Čiže ak p je pixel ciev, df_p bude vysoká hodnota. Naopak, keď p patrí pozadiu alebo lézií, táto hodnota bude nízka. V tejto metóde bol ďalej použitý multiscale line operátor na detekovanie ciev. Autori sa rozhodli pre 3 operátory s čiarami o dĺžkach 5, 11 a 15 pixelov v dvanástich rôznych smeroch. Výsledná hodnota pixelu bude maximálna hodnota spomedzi hodnôt vyhodnotených týmito operátormi. Posledným krokom spracovania je prahovanie hodnotou vybranou experimentálne, s cieľom konvertovať obraz na binárny.

Na testovanie boli použité dátové sady DRIVE a STARE. Na Drive dátovej sade vyšla presnosť predstavenej metódy na 93,87 %. Výsledky zo Stare dátovej sady sú u patologických obrazov 94,38 % presnosť a 94,83 % presnosť u celkovej dátovej sady. Hodnoty senzitivity a špecifickosti autori v článku neuvádzajú. Metóda teda vykazuje podobné výsledky ako iné algoritmy, s ktorými bola porovnávaná. Vďaka podobným výsledkom na oboch dátových

sadách je možné konštatovať, že metóda pracuje konzistentne v rôznych prípadoch. Na druhú stranu, algoritmus falošne detekoval niektoré tmavé lézie a šum pozadia. Taktiež bol zaznamenaný problém s detekciou najtenších ciev.

Optimalizácia rojom častíc

Optimalizácia rojom častíc je efektívna optimalizačná metóda, patriaca medzi algoritmy inšpirované prírodou. Častice sú kandidátne riešenia. Častice vyhodnocujú optimálne riešenie na základe svojej vlastnej skúsenosti, svojho najlepšieho riešenia, ktoré sa označuje ako pbest. Taktiež vyhodnocujú na základe najlepšieho riešenia skupiny - roja, ktoré je označované ako gbest. Výhoda tohto algoritmu v porovnaní s inými je v tom, že obsahuje len zopár parametrov, ktoré treba nastavovať, a tak je jednoduchý na implementáciu.

G. Hassan et al. [29] vo svojom algoritme použili prahovú segmentáciu optimalizovanú pomocou roja častíc. Cieľom bolo použiť na segmentáciu viacúrovňové prahovanie, ktorého problémom je správne automaticky zvoliť n-úrovňový prah. Tento problém je možné zmeniť na optimalizačný problém, kde je cieľom nájsť optimálny prah, ktorý bude maximalizovať objektovú funkciu.

Algoritmus bol implementovaný nasledovne: častice sú generované náhodným spôsobom s rozsahom minimálnej a maximálnej hodnoty prahu. Vyhodnotí sa objektová funkcia častice na základe ktorej sa inicializujú sa hodnoty pbest a gbest. Vypočítajú sa nové rýchlosti častíc a ich nové pozície. Znova sa vypočíta hodnotiaca funkcia pre každú časticu s jej novou pozíciou a aktualizujú hodnoty pbest a gbest. Ak boli dosiahnuté optimálne prahové hodnoty, pozícia častíc je reprezentovaná hodnotou gbest.

V inej štúdií [48] bola použitá táto optimalizácia na nájdenie vhodných parametrov L , σ a T matched filtru. L predstavuje dĺžku cievy v jednom smere, σ je mierka filtra a T je poloha, kde by sa Gaussova krivka mala orezať. Použili filter s dvoma váhami. Väčšie hodnoty na detekovanie veľkých ciev a malé hodnoty na detekovanie malých tenkých ciev.

Rozsah hodnôt jednotlivých parametrov použili nasledovný: $L_1 = \{1, 2, \dots, 10\}$, $\sigma_1 = \{1, 2, \dots, 10\}$, $T_1 = \{1, 2, \dots, 10\}$, $L_2 = \{1, 2, \dots, 10\}$, $\sigma_2 = \{1, 2, \dots, 10\}$, $T_2 = \{1, 2, \dots, 10\}$. Častica je kandidátne riešenie pozostávajúce zo sady $\{L_1, \sigma_1, T_1\}$ a $\{L_2, \sigma_2, T_2\}$. Po inicializácii roja a nastavení pozícií častíc a ich rýchlostí, v tomto prípade na 0, sú vygenerované 2 jadrá filtru s rôznymi uhlami otočenia. Vstupný obraz sa konvertuje za pomoci vygenerovaných filtrov, znásobí sa odozva filtra, aby sa potlačil šum a vypočíta sa plocha pod operačnou krivkou ROC, ktorá je použitá ako fitness funkcia. Aktualizuje sa rýchlosť a pozícia častíc. Tento cyklus sa opakuje, kým nie je dosiahnutý maximálny počet opakovaní alebo sa riešenie nemení.

Pri samotnej segmentácii je použitá zelená komponenta vstupného obrazu a v rámci predspracovania je aplikovaný mediánový filter, s väčším oknom 30×30 . Výsledný obraz tejto filtrácie je vyňatý z originálneho obrazu. Nasleduje filtrovanie pomocou matched filtra s parametrami získanými optimalizáciou a filtrovanie globálnym prahom. Za výsledné cievy sa považujú tie, ktoré sa nachádzajú v obraze vyňatom po mediánovej filtrácii a súčasne aj v obraze po filtrácii matched filtrom. Malé cievy sa odstraňujú, aby sa predišlo falošnej detekcii.

Obidva predchádzajúce popísané algoritmy boli testované a merané na DRIVE dátovej sade. Ako aj metóda navrhnutá *K.S. Sreejini, V.K. Govindan* [48], tak aj metóda použitá *G. Hassan et al.* [29] poskytujú lepšie výsledky ako iné metódy, ktoré boli v článku autormi porovnávané. Jednalo sa najmä o rozdiely v oblasti špecifickosti a presnosti.

Tabuľka 3.2: Porovnanie výsledkov metód segmentácie za použitia optimalizácie rojom častíc

Metóda	Senzitivita	Špecifickosť	Presnosť
Matched filter [48]	71,32	98,66	96,33
Prahovanie [29]	88,79	98,62	97,75

Algoritmus navrhnutý *K.S. Sreejini, V.K. Govindan* vykazuje lepšie výsledky pri použití viacstupňového filtra, než pri použití jedноступňového.

Systém kolónie mravcov

Systém kolónie mravcov patrí medzi algoritmy inšpirované prírodou. Mravce prehľadávajú okolie a snažia sa nájsť najkratšiu cestu k potrave. Počas prehľadávania vypúšťajú feromón, na základe ktorého následne vyhodnocujú najlepšiu cestu.

Ahmed Hamza Asad et al [17] [18] použili ako heuristickú funkciu Euklidovskú vzdialenosť medzi pixelom (i, j) a stredom ciev a triedami pozadia v priestore funkcií. V rámci zlepšenia algoritmu navrhli heuristickú funkciu založenú na teórii pravdepodobnosti. Navrhnuté boli dva spôsoby zlepšenia aktualizovacieho mechanizmu: na základe iterácie a na základe histórie. Pri aktualizovaní na základe iterácie sa aktualizuje level feromónu každého pixelu podľa toho, koľkokrát bol pixel navštívený v danej iterácii. Aktualizácia založená na histórii aktualizuje hodnotu feromónu na pixely na základe počtu návštev daného pixelu od začiatku behu algoritmu.

V článku [25], autori *M. G. Cinsdikici a D. Aydın* opisujú použitie systému kolónie mravcov a matched filter paralelne na jednom vstupnom obrázku a ich následné spojenie pomocou OR operátora. Navrhnutý algoritmus má nasledujúce kroky:

- **Predspracovanie:** zahŕňa extrakciu zeleného kanálu, vylepšenie obrazu a rozdelenie obrazu na menšie bloky. Rozdelenie na menšie bloky bolo inšpirované faktom, že na obraze z oftalmoskopu o rozmeroch 512 x 512 šírka cievy nepresahuje 15 pixelov. Tieto bloky sú označené, ak obsahujú časť cievy a sú použité ďalej v algoritme.
- **Algoritmus kolónie mravcov:** Každý blok je považovaný za graf a pixely sú vrcholmi grafu. Mravce sú náhodne rozložené na pixely a nasledovné kroky sú vybrané prechodovým pravidlom systému kolónie mravcov. Mravec môže zomrieť v dvoch prípadoch, a to ak nemá žiadny vhodný pixel, na ktorý by sa posunul alebo ak vyčerpá svoju pamäť. Potom čo mravci vykonajú svoje pohyby, aktualizuje sa level feromónov. Tento cyklus sa opakuje predom určený počet krát. Na záver sa zlúčia bloky a prebehne binarizácia. Binárny obraz je vygenerovaný pomocou prahovej hodnoty nad hladinou feromónu.
- **Matched filter algoritmus:** je aplikovaný na obraz s extrakciou zeleného kanálu, na ktorý je použitá normalizačná funkcia. Po normalizácii nasleduje zmena mierky pomocou LogSig funkcie na elimináciu odľahlých hodnôt. Ďalej je aplikovaný Gaussov filter.
- **Zjednotenie:** Binárny obraz vytvorený algoritmom kolónie mravcov a obraz vytvorený matched filterom sú spojené pomocou OR operátora. Následne sú odstránené nežiadúce nepripojené malé časti ciev, pomocou analýzy pripojených komponentov. Každá izolovaná časť je označená ako objekt a uložená do tabuľky s informáciou o dĺžke. Na

základe určené prahu sú z tabuľky a rovnako aj z obrázku odstránené nežiadúce časti ciev.

Experimenty navrhnutého algoritmu ukázali, že systém kolónie mravcov zlepšuje presnosť matched filteru. Na druhú stranu obsahuje nedostatky, ktoré by bolo treba vylepšiť. Medzi nedostatky tejto metódy patrí fakt, že cievy vo finálnom obraze sú hrubšie, ako je štandard. Taktiež fakt, že mravce chybné definujú patologické miesta ako cievy, a tak sa môžu objaviť vo finálnom obraze.

3.5 Sledovanie ciev

Pri sledovaní ciev sa automaticky alebo manuálne vyberajú body patriace hrane alebo stredovej osi cievy. Na základe daných bodov a smeru cievy sa vykoná malý krok v smere cievy a v blízkosti sa hľadajú body patriace hrane alebo osi. Keď sa nájdu nové hrany, vyráta sa približný smer a vykoná sa nový krok v danom smere [51].

Yi Yin *et al.* [51] navrhli iteratívny algoritmus sledovania, v ktorom sú inicializačné body vybrané manuálne. Body hrany sú následne detekované na základe štatistík lokálnych odtieňov šedej. Každá nová nájdená vetva je braná ako nová cieva, na ktorú je použitý ten istý algoritmus. Proces končí, keď je nájdený koniec cievy.

V každom kroku je vytvorená polkružnica, ktorá predstavuje prehľadávanú oblasť. Táto polkružnica by mala byť dynamická a adaptabilná, z dôvodu komplexných geometrických vlastností ciev. V prehľadávanom okne je nájdených niekoľko kandidátov na body hrany a na to, aby boli vybrané nové body patriace hrane je potrebný konfiguračný model. Autori tejto práce [51] vytvorili 3 typy konfigurácií na základe štruktúr ciev: normálna (samostatná cieva), rozdvojenie cievy a kríženie ciev. Ak sú zvolené 2 body, jedná sa o normálnu, samostatnú cievu. V prípade 4 bodov, ide o rozdvojenie cievy a v prípade 6 zvolených bodov sa jedná o kríženie ciev. Z týchto 6 bodov, 2 body patria aktuálnej cieve a zvyšné 4 novej. Body hrany cievy sú detekované pomocou Bayesovej metódy s kritériom maximálnej pravdepodobnosti (MAP).

Ďalším prístupom k sledovaniu ciev je použitie viacúrovňovej segmentácie. Urobili tak Marios Vlachos a Evangelos Dermatas vo svojej práci [50], kde algoritmus začína na malej skupine pixelov, ktoré boli vybrané na základe jasú. Odhad nového pixelu sa vykonáva z výberu množiny kandidátnych pixelov. Ku kandidátnemu pixelu sú vybrané 2 pixely pozadia v protiahlom smere a vo vzdialenosti polovičnej šírky profilu prierezu cievy. Ak kandidátny pixel patrí cieve, hodnota prierezového parametru bude vysoká. V opačnom prípade sa bude hodnota približovať nule, pretože hodnoty kandidátneho pixelu a hodnoty pixelov pozadia sú podobné.

Viacúrovňové sledovanie sa vykonáva predom určený počet opakovaní. Počet úrovní, a teda aj opakovaní, sa určuje na základe veľkosti priemeru rúrkovitých štruktúr, ktoré sú detekované v obraze. V prípade veľkej odchýlky priemerov ciev je potreba viac úrovní. V algoritme sa taktiež používa počiatočný odhad siete ciev za pomoci jednoduchého výberového procesu s názvom kvantifikácia mapy. Je vytvorená z pixelov s hodnotou matice spoľahlivosti vyššou, ako je prahová hodnota. Ďalej sa mediánovým filtrom vyplnia medzery v sieti ciev. Na odstránenie chybnéj klasifikácie mediánovým filtrom je obraz transformovaný pomocou morfológického otvorenia vo viacerých smeroch. Na záver je aplikovaný proces zvaný morfológická rekonštrukcia. Cieľom je odstrániť chybné detekované pixely.

3.6 Segmentácia tenkých a hrubých ciev

Analýza snímok očného pozadia ukazuje, že pixely hrubých ciev a pixely tenkých ciev majú odlišný kontrast oproti pozadiu. Na základe toho je možné uskutočniť segmentáciu tenkých a hrubých ciev samostatne [26].

Jedným z prístupov je použitie k-means zhlučovacieho algoritmu. Autori článku [26] navrhli algoritmus, v ktorom bol obraz najprv prespracovaný pomocou CLAHE metódy a optimalizovanou top-hat transformáciou. Na takto prespracovaný obraz bolo aplikované k-means zhlučovanie. Autori vo svojej práci predpokladajú, že pixely hrubých ciev budú priradené do jednej triedy a pixely tenkých ciev budú patriť nižšej triede. Obidve triedy boli samostatne extrahované z obrazu. Trieda hrubých ciev vytvorila kostru. Trieda tenkých ciev bola následne spracovaná filtrovaním a ďalším k-mean zhlučovaním, po ktorom sa predpokladá, že pixely ciev boli priradené najvyššej triede. Na záver sa obraz s hrubými cievami a obraz s tenkými cievami spojili a vytvoril sa výsledný obraz.

Algoritmus bol otestovaný na DRIVE dátovej sade. Autori v práci neuvádzajú výsledné namerané hodnoty pre celú dátovú sadu. Hodnoty pre jednotlivé snímky uvedené v práci sú priemerne 95,78 % pre presnosť, 76,68 % pre senzitivitu a 97,45 % pre špecifickosť [26].

V práci [34] bol použitý rovnaký postup prespracovania ako v prechádzajúcom algoritme. Z obrazu, ktorý bol upravený CLAHE metódou a optimalizovanou top-hat transformáciou, bola vypočítaná druhá derivácia pre tenké a hrubé cievy osobitne. To bolo dosiahnuté pomocou Hessovej matice a transformáciou vlastných čísiel. Na obraz hrubých ciev bolo aplikované globálne Otsu prahovanie, ktorý bol následne spojený s upraveným obrazom tenkých ciev. Na spojený obraz bolo aplikované lokálne prahovanie.

Na vyhodnotenie algoritmu boli použité DRIVE a STARE dátové sady s priemernou hodnotou presnosti 96,08 % pre DRIVE dátovú sadu a 94,59 % pre STARE dátovú sadu.

Kapitola 4

Návrh algoritmu

4.1 Implementácia

Aplikácia bola implementovaná v jazyku Python, verzia 3.9 [11]. Využíva knižnicu OpenCV [9] a Scikit-image [13] na spracovanie obrazu a knižnicu NumPy [8] na prácu s viacrozmerným polom obrazu. Taktiež sú využité funkcie knižnice Scikit-learn [14], ktorá podporuje strojové učenie a ponúka napríklad aj nástroje na vyhodnotenie klasifikácie.

4.2 Získanie masky

Získanie masky pozadia bolo potrebné na odstránenie prebytočných informácií v pozadí. Maska pozadia sa vytvorí jednoducho pomocou prahovacej techniky Otsu prahovanie.

Otsu prahovanie patrí medzi globálne prahovacie algoritmy. Základná myšlienka za touto prahovacou metódou je rozdeliť histogram obrazu do dvoch zhlukov. Najlepšie teda pracuje na bimodálnych obrazoch. Otsu algoritmus sa snaží nájsť prah, ktorý minimalizuje vážený rozptyl v triede [16].

Snímky, ktoré obsahujú na okraji sietnice tmavú škvrnu alebo tien, sú spracované touto prahovacou technikou tak, že časti sietnice sú klasifikované ako pozadie. Takúto snímku ukazuje obrázok 4.1 a jej masku obrázok 4.2. Pre lepší kontrast sietnice od pozadia som na vytvorenie masky použila modrý kanál obrazu, ktorý je zobrazený na obrázku 4.3. V tomto prípade sa znížil výskyt nesprávne detekovaných tmavých častí sietnice. Na vyplnenie dier v maske sietnice je aplikované morfologické otvorenie, ktoré vyhladí masku v prípade, že pôvodná snímka obsahovala výrazne tmavé škvrny a tiene.

4.3 Predspracovanie


Prvým krokom predspracovania je extrakcia zeleného kanálu. Tento kanál sa vyberá z dôvodu najlepšieho kontrastu medzi cievami a pozadím. Ako je možné pozorovať na obrázkoch 4.3 - 4.5, v obraze s modrým a s červeným kanálom sa tenké cievy úplne strácajú a v obraze zeleného kanálu sú tenké cievy lepšie viditeľné.

Druhým krokom je rozmazanie Gaussovým filtrom. Veľkosť matice som zvolila rôznu pre rôzne šírky snímky, viď tabuľka 4.1. Vďaka vlastnostiam Gaussovho filtra, ktoré sú popísané v sekcii 3.1, je zmiernený šum pozadia, ale hrany ciev zostávajú viditeľné.

Následne je potrebné zvýšiť kontrast ciev od pozadia. Na vylepšenie kontrastu som použila adaptívne rozdelenie histogramu s obmedzeným kontrastom, skrátene CLAHE me-



Obr. 4.1: Snímka sietnice s výrazným tieňom




Obr. 4.2: Maska oblasti záujmu pre snímku s tieňom

Tabuľka 4.1: Veľkosť Gaussovho filtra pri predspracovaní pre rôzne šírky snímky


Maximálna šírka snímky	Veľkosť filtra
900	9×9
1400	13×13
2000	19×19

tóda. Táto metóda pracuje na menších regiónoch obrazu. V každom regióne je vykonaná ekvalizácia histogramu.


Čierna top-hat transformácia na záver predspracovania extrahuje cievy od pozadia. Táto operácia vráti tmavé body v obraze ako svetlé, ktoré sú menšie ako štrukturálny element. Použitý bol štrukturálny element v tvare disku s polomerom 8 pixelov.



Obr. 4.3: Modrý kanál



Obr. 4.4: Zelený kanál



Obr. 4.5: Červený kanál

4.4 Segmentácia ciev

Pri segmentácii krvných ciev som použila zhlučovací algoritmus k-means a Frangiho filter.

Pre k-means zhlučovanie bolo vybraných $k = 10$ zhlučkov. Počiatočné stredy boli inicializované na náhodné hodnoty pomocou príznaku `KMEANS_RANDOM_CENTERS`, dostupného z knižnice OpenCV. Kritériom zastavenia výpočtu zhlučovania je dosiahnutie maximálne počtu iterácií alebo dosiahnutie určitej presnosti.

Frangiho algoritmus umožňuje detekciu rúrkovitých štruktúr v obraze. Hodnotu σ , ktorá určuje očakávanú šírku ciev, som zvolila v rozmedzí od 0,2 do 2,7 s veľkosťou kroku 0,5. Tieto hodnoty pre parameter σ zabezpečia, že sa nájdu ako tenké cievy, tak aj hrubé. Hodnota α , ktorá ovplyvňuje senzitivitu algoritmus na tanierovité štruktúry, je nastavená na konštantu 0,5 a hodnota β , ktorá ovplyvňuje citlivosť filtru na kvapkovité štruktúry, je zvolená na konštantu 15. Funkcia je zároveň nastavená tak, aby vyhľadávala svetlé štruktúry.

Obraz vytvorený frangiho funkciou je normalizovaný na intervale 0 až 255. Je to z dôvodu, že funkcia `frangi` vracia obraz s hodnotami s dátovým typom float. Aby bolo možné s obrazom ďalej pracovať, hodnoty bolo potrebné normalizovať a pretypovať.

Na obraz s nájdenými cievami je aplikovaná prahovacia funkcia. Prah je zvolený na strednú hodnotu intenzít pixelov v snímke.

Extrakcia hrubých ciev


Pre extrakciu hrubých ciev z obrazu som navrhla k-means zhlučovací algoritmus. Zhlučovanie sa vykoná na predspracovanom snímku, s počtom stredov stanovených na $k = 3$, s náhodnými inicializačnými hodnotami. Predpokladá sa, že cievy, ktoré sa označujú ako hrubé, majú najvyšší kontrast oproti pozadiu a tak ich pixely budú klasifikované do najvyššej triedy S_3 . Výsledok zhlučovania je možné vidieť na obrázku 4.6.

Výsledný obraz I_1 (4.7) obsahujúci hrubé cievy vznikne nasledovne:


$$I_1(i, j) = \begin{cases} 255, & \text{pre } (i, j) \in S_3 \\ 0, & \text{inak} \end{cases} \quad i = \{1, 2, \dots, N_w\} j = \{1, 2, \dots, N_h\} \quad (4.1)$$

kde N_w a N_h predstavujú šírku a výšku obrazu.


Nakoľko sa do tejto triedy priradia aj iné pixely, ktorých hodnota je vyššia aj keď nepatria hrubej cieve, použije sa morfológická operácia otvorenia.



Obr. 4.6: Výsledok zhlučovania, kde $k = 3$



Obr. 4.7: Obraz hrubých ciev



Obr. 4.8: Manuálne segmentovaný obraz

Extrakcia tenkých ciev

Z hľadiska rozdelenia ciev na tenké a hrubé vznikajú 2 kategórie. V prípade, že je možné segmentovať cievy na snímke a taktiež je možné určiť hrubé cievy, ostatné detekované cievy, ktoré nie sú označené ako hrubé, je možné označiť za tenké.

Na vytvorenie obrazu tenkých ciev som použila predom segmentovaný obraz ciev a obraz s cievami určenými ako hrubé. Tieto dva obrazy som spracovala pomocou binárnej operácie XOR. Tým boli zo snímky s celkovou segmentáciou odstránené hrubé cievy. Vzniknutý obraz teda obsahuje len cievy, ktoré sa zaraďujú do kategórie tenkých ciev.

4.5 Záverečné spracovanie

Celkový obraz ciev, obraz hrubých ciev a aj obraz tenkých ciev je na záver spracovaný morfológickou operáciou otvorenia. Táto operácia odstráni mierny šum vytvorený nesprávnou detekciou pixelov pozadia.

U celkovej segmentácie takýto šum taktiež spôsobujú tenké cievy, ktoré majú slabý kontrast a nepodarilo sa ich segmentovať. U obrazu hrubých ciev to sú pixely zaradené do najvyššej triedy zhlukovanie, ktoré nie sú v blízkosti hrubej cievy. V obraze tenkých ciev je odstraňovaný najmä šum spôsobený odpočítaním obraz hrubých ciev od obrazu celkovej segmentácie.

4.6 Testovací skript

Testovací skript slúži na vyhodnotenie úspešnosti algoritmu. Skript načíta celú spracovanú dátovú sadu, vrátane samostatných hrubých ciev. Ďalej skript vyžaduje príslušné manuálne segmentované snímky.

Z manuálne segmentovaných snímok a snímok celkovej segmentácie, je vytvorená matica zámeny. Z matice zámeny sú ďalej vypočítané hodnoty pre presnosť, senzitivitu a špecifickosť. Tieto hodnoty sú vypočítané pre každú snímku samostatne a zároveň je vytvorený priemer pre danú dátovú sadu.

Skript taktiež vypočíta počet nenulových pixelov v snímke celkovej segmentácie a tiež v snímke s hrubými cievami. Z týchto informácií sa vyhodnotí, koľko percent detekovaných pixelov ciev, bolo priradených do triedy hrubých a tenkých ciev.

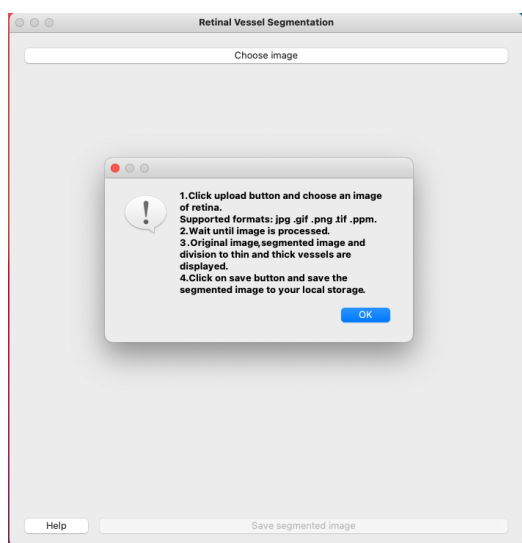
4.7 Aplikácia

Užívateľské rozhranie výslednej desktopovej aplikácie bolo vytvorené v Python frameworku PyQt5 [12].

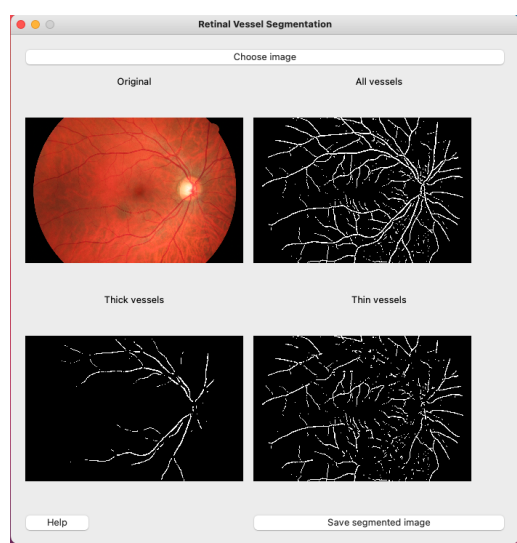
Aplikácia umožňuje užívateľovi nahrať fotografiu vo formáte .jpg, .gif, .png, .tif, .pgm alebo .ppm. Snímka je spracovaná pomocou navrhnutého segmentačného algoritmu. Výsledok celkovej segmentácie, ale aj snímky hrubých a tenkých ciev, sú užívateľovi zobrazené v aplikácii. Ukážka snímky obrazovky z aplikácie je zobrazená na obrázku 4.10. Výsledok celkovej segmentácie je možné uložiť do lokálneho úložiska. Užívateľ si taktiež môže zobrazit nápovedu aplikácie, ktorá je zobrazená na obrázku 4.9.

Inštalácia softvéru bola vytvorená pomocou Inno Setup Compiler[5]. Vďaka tomu, si užívateľ môže aplikáciu jednoducho nainštalovať na operačný systém Windows. Spustiteľný súbor bol vytvorený pomocou knižnice PyInstaller[10].

Aplikácia je dostupná pod GNU GPL[4] licenciou pre slobodný softvér.



Obr. 4.9: Snímka obrazovky užívateľskej aplikácie - výpis nápovedy



Obr. 4.10: Snímka obrazovky užívateľskej aplikácie - segmentované snímky

Kapitola 5

Testovanie

5.1 Dátové sady

Pri testovaní boli použité nasledovné voľne dostupné dátové sady:

DRIVE

Fotografie tejto dátovej sady boli získané počas screeningového programu diabetickej retinopatie v Holandsku. Screeningová populácia pozostávala zo 400 subjektov vo veku 25-90 rokov. Z vytvorených fotografií bolo následne 40 náhodne vybraných pre túto dátovú sadu. 33 fotografií neprejavuje žiadne známky diabetickej retinopatie, a teda sú to obrázky zdravej sietnice. Na 7 fotografiách je možné pozorovať mierne znaky tohto ochorenia.

Dátová sada bola rozdelená do dvoch kategórií: testovacia a trénovacia sada. Trénovacia sada obsahuje pre každý obraz jeden manuálne segmentovaný obraz. Obidve sady obsahujú manuálne segmentované masku, ktorá predstavuje región záujmu.

Fotografie boli získané pomocou kamery Canon CR5 non-mydratic 3CCD so 45 stupňovým uhlom pohľadu. Veľkosť výslednej fotografie je 768×584 pixelov s farebnou hĺbkou 8 bitov.[2]

HRF

Táto databáza bola vytvorená výskumnou skupinou na Friedrich-Alexander Univerzite v Nemecku s cieľom podporiť vývoj segmentačných algoritmov. Dátová sada aktuálne pozostáva z 3 kategórií fotografií. Každá kategória obsahuje 15 fotografií sietnice a pre každú fotografiu príslušnú masku pozadia a manuálne segmentovú sietnicu. Prvá kategória obsahuje fotografie sietnice zdravých pacientov, fotografie druhej kategórie preukazujú znaky diabetickej retinopatie a posledná kategória bola vytvorená z fotografií pacientov s glaukómom.

Fotografie boli zachytené fundus kamerou Canon CR-1 s uhlom pohľadu 45 stupňov. Výsledný obraz má rozmery 3264×4928 pixelov.[22][23]

5.2 Meranie úspešnosti metód

Pri vyhodnocovaní výsledkov segmentácie sa určuje senzitivita, špecifickosť a presnosť. Tieto vlastnosti sa určujú na základe nasledovných rovníc 5.1, 5.2, 5.3:

$$\text{Senzitivita} = TP/(TP + FN) \quad (5.1)$$

$$\text{Špecifickosť} = TN/(TN + FP) \quad (5.2)$$

$$\text{Presnosť} = (TP + TN)/(TP + TN + FP + FN) \quad (5.3)$$

kde TP = True Positive, čiže správne detekované pixely ciev, TN = True Negative, teda správne detekované pixely pozadia. FP = False Positive predstavuje pixely pozadia, ktoré sú klasifikované ako pixely ciev a FN = False Negative sú pixely ciev nesprávne klasifikované ako pozadie.

Senzitivita meria schopnosť segmentovacieho algoritmu správne detegovať pixely patriace cieve. Špecifickosť predstavuje schopnosť algoritmu detegovať pixely pozadia. Presnosť ukazuje mieru zhody segmentovaného obrazu s manuálne segmentovaným obrazom, ktorý predstavuje základnú pravdu.


5.3 Vyhodnotenie navrhnutej metódy

DRIVE dátová sada


Na vyhodnotenie úspešnosti na DRIVE dátovej sade som použila trénovaciu množinu snímok, nakoľko k tejto sade prináležia aj manuálne segmentované snímky.

Pri predspracovaní Gaussovým filtrom o veľkosti 9×9 , top-hat transformácií so štruktúrnym prvkom v tvare disku s polomerom 8 a následným zhlukovaním s počtom stredov $k = 10$, priemerné výsledky vyšli nasledovne: 56,00 % pre senzitivitu, 88,43 % pre špecifickosť a 81,65 % pre presnosť.


Ako je možné vidieť na obrázku 5.1 v porovnaní so štandardom na obrázku 5.3, navrhnutý algoritmus nedokáže dostatočne detegovať tenké cievky. Obrázok 5.2 zobrazuje pixely a cievky, ktoré neboli nájdené. Taktiež je možné pozorovať, že nájdené cievky pôsobia hrubšie ako cievky na manuálne segmentovanej snímke.



Obr. 5.1: Segmentácia navrhnutým postupom



Obr. 5.2: Nedetekované pixely



Obr. 5.3: Manuálne segmentovaná snímka

HRF dátová sada


Ako už bolo spomenuté v sekcii 5.1, snímky dátovej sady majú veľkosť 3264×4928 . Kvôli urýchleniu spracovania som sa rozhodla snímky s podobnými rozmermi zmenšiť na polovičnú veľkosť, a to konkrétne snímky so šírkou nad 2000 pixelov. Na zmenšenie bola použitá interpolačná metóda `INTER_AREA`. Táto metóda je často používaná pri zmenšovaní obrazu.

Ako prvú testovaciu sadu z tejto dátovej sady som zvolila kategóriu snímok zdravých sietnic. Pri predspracovaní som pri snímku s väčšími rozmermi zvolila Gaussov filter o veľkosti 19×19 . Štrukturálny element top-hat transformácie v tvare disku bol zvolený na veľkosť 8 a zhlukovanie na $k = 10$ zhlukov. Dosiahnuté výsledky na tejto dátovej sade sú 73,36 % pre senzitivitu, 94,11 % pre špecifickosť a 91,93 % pre presnosť.

Na obrázku 5.4 je možné vidieť, že algoritmus dokáže lepšie detegovať tenké cievy, oproti Drive dátovej sade 5.1. Avšak v porovnaní s manuálne segmentovanou snímku 5.5, mnohé tenké cievy ostali nenájdene.



Obr. 5.4: Segmentácia navrhnutým postupom



Obr. 5.5: Manuálne segmentovaná snímka

Algoritmus však nezohľadňuje ani nedeteguje ochorenia sietnice. Pri rovnakom nastavení parametrov ako u snímkach zdravej sietnice, vyhodnotenie segmentácie dopadlo nasledovne: Segmentácia snímok s glaukómom má presnosť 91,69 %, špecifickosť 93,15 % a senzitivitu 74,90 %. Snímky s prejavom diabetickej retinopatie ukazujú výsledky s presnosťou 89,26 %, špecifickosť 90,51 % a senzitivita metódy je 75,29 %.

Tabuľka 5.1: Vyhodnotenie segmentácie v %

Dátová sada	Senzitivita	Špecifickosť	Presnosť
DRIVE	56,00	88,43	81,65
HRF zdravé	73,36	94,11	91,93
HRF glaukóm	74,90	93,15	91,69
HRF DR	75,29	90,51	89,26
Priemer	69,89	91,55	88,63

5.4 Vyhodnotenie rozdelenia ciev

V nasledujúcej sekcií bude popísané vyhodnotenie rozdelenia ciev na tenké a hrubé. Nakoľko nie sú známe žiadne práce, ktoré sa venujú takémuto rozdeleniu ciev, algoritmus nie je možné porovnať a vyhodnotiť jeho úspešnosť. Z tohto dôvodu som sa rozhodla rozdelenie ciev vyhodnotiť štatisticky, a to percentuálnym rozdelením ciev. Zároveň táto sekcia obsahuje aj analýzu pozorovaním, ktorá opisuje správnosť detegovania hrubých ciev.

DRIVE dátová sada

Analýza

Ako bolo spomenuté v kapitole 4, algoritmus predpokladá, že pixely, ktoré sú pri zhlukovaní pridelené do najvyššej triedy, patria hrubým cievm.

Z obrázku 5.6 je možné vyhodnotiť, že najvýraznejšie cievy boli detegované ako hrubé. Tieto najvýraznejšie cievy sú však v popredí sietnice. Ako je možné vidieť na manuálne segmentovanej snímke 5.8, v porovnaní s detegovanými cievmi 5.7, algoritmus nie je schopný detegovať všetky hrubé cievy, ktoré sú na pozadí.


Tento istý jav sa objavuje aj u ďalších snímok. Séria obrázkov 5.9, 5.10, 5.11 ukazuje, že niektoré cievy, ktoré sa zdajú byť v popredí, neboli detegované až do konca. Väčšina hlavných ciev, ktoré však majú dostatočný kontrast s pozadím sietnice, je nájdená a priradená triede hrubých ciev.



Obr. 5.6: Pôvodná snímka sietnice: 22_training



Obr. 5.7: Detekované hrubé cievy



Obr. 5.8: Manuálne segmentovaná snímka


Štatistiky

Algoritmus pri použití Drive dátovej sady má senzitivitu, a teda schopnosť správne detegovať pixely ciev, priemerne 56,00 %. Z týchto detegovaných pixelov, je v priemere, zo všetkých snímok trénovacej sady, 24,11 % pixelov priradených hrubým cievm. Zvyšných 75,89 % detegovaných pixelov patrí cievm tenkým. Z toho vyplýva, že až tri štvrtiny ciev v obraze patrie tenkým cievm.


Tabuľka 5.2 ukazuje, že množstvo pixelov priradených tenkým cievm sa pohybuje v rozmedzí 71 % až takmer 85 %. V tabuľke sú vypísané hodnoty pre vybrané snímky dátovej sady. Obrázok 5.10, ktorý predstavuje hrubé cievy snímky 5.9 s názvom 40_training, predstavuje až 28.39 % zo všetkých segmentovaných ciev. Ako je možné vidieť v tabuľke 5.2,



Obr. 5.9: Pôvodná snímka sietnice: 40_training



Obr. 5.10: Detegované hrubé cievy



Obr. 5.11: Manuálne segmentovaná snímka

podobný počet hrubých ciev bol detegovaný aj pre snímku 5.6 s názvom 22_training, a to 27,76 %

Tabuľka 5.2: Vyhodnotenie spracovania vybraných snímok Drive dátovej sady

Názov snímky	Senzitivita segmentácie	Hrubé cievy v %	Tenké cievy v %
22_training	55,26	27,76	72,24
24_training	55,67	17,16	82,84
27_training	56,57	15,68	84,32
29_training	56,29	27,45	72,55
38_training	56,52	25,12	74,88
39_training	55,70	39,71	60,29
40_training	57,51	28,39	71,61
Priemer dátovej sady	56,00	24,11	75,89

HRF dátová sada

Analýza

Pri použití HRF dátovej sady je možné pozorovať lepšie detegovanie ciev oproti DRIVE dátovej sade. Ako už ukazujú výsledky segmentácie v predchádzajúcej sekcii, priemerná senzitivita je 74,51 %.

Na obrázku 5.14 je možné vidieť, že sú zobrazené takmer všetky výrazné cievy, ktoré sú označené ako hrubé na manuálne segmentovanej snímke 5.13. Medzi tenké cievy sa však zaradili zakončenia hrubých ciev. To je spôsobené tým, že ich pixely majú nižšiu intenzitu a tak sa pri zhlukovaní nezaradia do najvyššej triedy.

Štatistiky

Pixely ciev, ktoré je možné vidieť na obrázku 5.14 tvoria až 22,12 % z celkovej siete ciev. Zvyšných 77,88 % tvoria tenké cievy zobrazené na obrázku 5.15.


Priemerné výsledky zo všetkých kategórií HRF dátovej sady ukazujú väčšie percento tenkých ciev oproti DRIVE dátovej sade. Pri vyhodnotení rozdelenia ciev u snímok zdravej sietnice vyšlo, že až 79,07 % pixelov patrí tenkým cievm. Pri snímkach sietnice s glaukó-

Tabuľka 5.3: Vyhodnotenie vybraných snímok s diabetickou retinopatiou z HRF dátovej sady


Názov snímky	Senzitivita segmentácie	Hrubé cievy v %	Tenké cievy v %
01_dr	79,51	15,09	84,91
05_dr	78,27	18,86	81,14
10_dr	71,03	21,75	78,25
13_dr	78,90	13,55	86,45
Priemer dátovej sady	75,29	17,41	82,59

mom priemerne až 79,40 % pixelov patrí cievam a pri snímkach s diabetickou retinopatiou je to až 82,59 %.


Na základe týchto zistení, ale aj na základe vyhodnotenia celkovej segmentácia v sekcii 5.3 je možné zhodnotiť, že algoritmus dokáže lepšie detegovať tenké cievy pri celkovej segmentácii u HRF dátovej sady v porovnaní s DRIVE dátovou sadou.




Obr. 5.12: Pôvodná snímka sietnice: 08_h



Obr. 5.13: Manuálna segmentácia



Obr. 5.14: Detegované hrubé cievy



Obr. 5.15: Detegované tenké cievy

Tabuľka 5.4: Vyhodnotenie vybraných snímok so zdravou sietnicou z HRF dátovej sady

Názov snímky	Senzitivita segmentácie	Hrubé cievy v %	Tenké cievy v %
08_h	73,70	22,12	77,88
09_h	71,54	15,33	84,67
11_h	78,41	21,68	78,32
15_h	81,60	18,24	81,76
Priemer dátovej sady	73,36	20,93	79,07

Tabuľka 5.5: Vyhodnotenie vybraných snímok s glaukómom z HRF dátovej sady

Názov snímky	Senzitivita segmentácie	Hrubé cievy v %	Tenké cievy v %
01_g	77,40	16,30	83,70
02_g	75,20	22,84	77,16
04_g	76,14	17,24	82,76
14_g	74,72	27,65	72,35
Priemer dátovej sady	74,90	20,60	79,40

5.5 Experimenty

Prvé dva experimenty sa venujú k-means zhľukovaniu s rôznym počtom stredov a ich vplyv na výslednú segmentáciu ciev. Tretí experiment sa venuje použitiu medianového filtra namiesto filtra Gaussovhovho v predspracovaní.

Experiment č. 1

Cieľom tohto experimentu bolo zistiť, či zhľukovanie s väčším počtom stredov vo výslednej segmentácii dáva lepšie výsledky ako zhľukovanie s menším počtom stredov. Zo spracovania som vynechala k-means zhľukovanie do $k = 10$ zhľukov. Vykoná sa zhľukovanie do $k = 3$ zhľukov, ktoré je použité na extrakciu hrubých ciev. Ak sa predpokladá, že hrubé cievy sú priradené do najvyššej triedy S_3 , taktiež je možné predpokladať, že pixely pozadia sa priradia do najnižšej triedy S_1 . Z toho vyplýva, že tenké cievy patria triede S_2 .

Pri testovaní na DRIVE dátovej sade som zistila, že celková priemerná presnosť segmentácie sa nelíši od navrhnutého algoritmu. V tomto prípade výsledky testovania dopadli nasledovne: presnosť 81,21 %, špecifickosť 87,73 % a senzitivita 56,55 %. Testovanie na HRF dátových sadách taktiež ukázalo malý rozdiel oproti navrhnutej metóde, a to približne o 2 %. Priemerné hodnoty pre všetky tri sady HRF dátovej sady vyšli na presnosť 91,28 %, špecifickosť 93,13 % a senzitivita 71,91 %.

Experiment č. 2

Nakoľko predchádzajúci experiment ukázal mierne nižšie výsledky oproti navrhnutej metóde, tento experiment zisťuje, či zhľukovanie do väčšieho počtu zhľukov, ako som navrhla, zlepši presnosť algoritmu.

Počet stredov som v tomto prípade zvolila na $k = 15$. Výsledky testovania dopadli veľmi podobne ako výsledky navrhnutej metódy. Drive dátová sada má v tomto prípade výsledky 81,75 % pre presnosť, 88,65 % pre špecifickosť a 55,64 % pre senzitivitu. Namerané hodnoty u dátovej sady HRF sú 91,15 % pre presnosť, 92,88 % pre špecifickosť a 73,72 %

pre senzitivitu. Tieto hodnoty neukazujú rozdiel ani pol percenta proti zhlukovaniu s 10 stredmi. Z toho môžeme usúdiť, že zhlukovanie s počtom stredov 10, ponúka v navrhnutej metóde najlepšie možné výsledky.

Experiment č. 3

Tento experiment zisťuje, aký vplyv na výsledné hodnoty má nahradenie Gaussovho filtra Medianovým filtrom. V tomto prípade som pre obidve dátové sady zvolila jadro o veľkosti 9. Presnosť a špecificita sa nejak významne nezmenili. Priemerná senzitivita u obidvoch dátových sadách však klesla o 5 %. Táto hodnota ukazuje, že bolo detekovaných menej cieľ, ako pri použití Gaussovho filtra.

Kapitola 6

Záver

Cieľom tejto práce bolo navrhnúť algoritmus segmentovania krvných ciev sietnice oka a segmentované cievy následne rozdeliť do dvoch skupín - tenké a hrubé.

Navrhla som algoritmus, ktorý začína predspracovanie vyhladením snímky pomocou Gaussovho filtra, následne sa zvýši kontrast CLAHE metódou. Čierna top-hat transformácia zabezpečí inverziu snímky, a tak vznikne obraz s tmavým pozadím sietnice a výraznými svetlými cievami. V rámci predspracovania je taktiež získaná maska pozadia pomocou prahovacej techniky Otsu, ktorá vymedzí región záujmu pre ďalšie spracovanie. Celková segmentácia ciev je vykonaná zhlukovaním metódou najbližších stredov, teda k-means, a Frangiho algoritmom, ktorý slúži na detekciu rúrkovitých štruktúr v obraze. Detekcia hrubých ciev predpokladá, že pri zhlukovaní s počtom stredov 3, sa pixely všetkých hrubých ciev priradia do najvyššej triedy. Na základe toho je vytvorený nový obraz s pixelmi patriacimi najvyššej triede, a teda hrubými cievami. Nakoľko sa v obraze nachádzajú len 2 kategórie ciev, obraz tenkých ciev je vytvorený binárnou operáciou xor snímky hrubých ciev a snímky so všetkými segmentovanými cievami. Záverečné spracovanie využíva morfológickú operáciu otvorenia na odstránenie mierneho šumu zo snímky.

Vyhodnotenie algoritmu bolo vykonané na dvoch verejne dostupných dátových sadách - Drive a HRF. Výsledné priemerné hodnoty pre obe dátové sady predstavujú 69,89 % pre senzitivitu, 91,55 % pre špecificitu a 88,63 % pre presnosť. Rozdelenie ciev do dvoch kategórií, tenké a hrubé, ukázalo, že v priemere 21,50 % pixelov v obraze tvorí hrubé cievy a zvyšným 78,50 % patrí cievam tenkým.

Na základe vyhodnotenia je vidieť, že algoritmus nedokáže dostatočne detegovať tenké cievy, ktorých kontrast je nízky oproti pozadiu a šumu pozadia. Pre zlepšenie tejto práce by bolo vhodné sa zamerať na odstránenie šumu z pozadia pri predspracovaní s dôrazom na zachovanie najtenších ciev. Čo sa týka rozdelenia ciev, testovanie ukázalo, že pri zhlukovaní do 3 kategórií sa do najvyššej kategórie nepriradia hrubé cievy, ktorých intenzita je nižšia oproti ostatným hrubým cievam, ktoré sú viac na popredí sietnice. V rámci zlepšenia algoritmu by bolo treba modifikovať k-means zhlukovanie, tak aby bolo možné zoskupiť všetky hrubé cievy.

Literatúra

- [1] *Canny Edge Detection* [online]. OpenCV [cit. 2020-12-30]. Dostupné z: https://docs.opencv.org/master/da/d22/tutorial_py_canny.html.
- [2] *DRIVE: Digital Retinal Images for Vessel Extraction* [online]. Dostupné z: <https://drive.grand-challenge.org/>.
- [3] *Fundus Photography Overview* [online]. Ophthalmic photographers' society [cit. 10.01.2021]. Dostupné z: <https://www.opsweb.org/page/fundusphotography>.
- [4] *The GNU General Public License* [online]. [cit. 02.05.2021]. Dostupné z: <https://www.gnu.org/licenses/licenses.en.html#GPL>.
- [5] *Jrsoftware.org // Jordan Russell's Software* [online]. [cit. 02.05.2021]. Dostupné z: <https://jrsoftware.org/isinfo.php>.
- [6] *The Lenna story* [online]. [cit. 15.04.2021]. Dostupné z: <http://www.lenna.org/>.
- [7] *Morphological Transformations* [online]. OpenCV [cit. 20.04.2021]. Dostupné z: https://docs.opencv.org/master/d9/d61/tutorial_py_morphological_ops.html.
- [8] *NumPy* [online]. [cit. 24.04.2021]. Dostupné z: <https://numpy.org/>.
- [9] *OpenCV* [online]. [cit. 24.04.2021]. Dostupné z: <https://opencv.org/>.
- [10] *PyInstaller* [online]. [cit. 02.05.2021]. Dostupné z: <https://www.pyinstaller.org/>.
- [11] *Python* [online]. [cit. 24.04.2021]. Dostupné z: <https://www.python.org/>.
- [12] *Qt for Python* [online]. [cit. 22.04.2021]. Dostupné z: <https://doc.qt.io/qtforpython/>.
- [13] *Scikit-image, image processing in python* [online]. [cit. 24.04.2021]. Dostupné z: <https://scikit-image.org/>.
- [14] *Scikit-learn, Machine Learning in Python* [online]. [cit. 24.04.2021]. Dostupné z: <https://scikit-learn.org>.
- [15] *STAVBA A FUNKCIA LUDSKÉHO OKA* [online]. Eurooptik, súkromná očná klinika [cit. 10.01.2021]. Dostupné z: <http://www.eurooptik.sk/stavba-funkcia-oka.php>.
- [16] ANASTASIA MURZOVA, A. S. *Otsu's Thresholding with OpenCV*. 2020. Dostupné z: <https://learnopencv.com/otsu-thresholding-with-opencv/>.

- [17] ASAD, A. H., AZAR, A. T., FOUAD, M. M. M. a HASSANIEN, A. E. An improved ant colony system for retinal blood vessel segmentation. In: *2013 Federated Conference on Computer Science and Information Systems*. 2013, s. 199–205.
- [18] ASAD, A. H., EID EL AMRY, HASSANIEN, A. E. a TOLBA, M. F. New global update mechanism of ant colony system for retinal vessel segmentation. In: *13th International Conference on Hybrid Intelligent Systems (HIS 2013)*. 2013, s. 221–227.
- [19] ASWINI, S., SURESH, A., PRIYA, S. a SANTHOSH KRISHNA, B. V. Retinal Vessel Segmentation Using Morphological Top Hat Approach On Diabetic Retinopathy Images. In: *2018 Fourth International Conference on Advances in Electrical, Electronics, Information, Communication and Bio-Informatics (AEEICB)*. 2018, s. 1–5. DOI: 10.1109/AEEICB.2018.8480970.
- [20] BJ. ZOU, C. Z. Supervised Vessels Classification Based on Feature Selection. *JOURNAL OF COMPUTER SCIENCE AND TECHNOLOGY*. November 2017, zv. 32, s. 1222–1230. DOI: 10.1007/s11390-017-1796-x.
- [21] BORSE, M. S. Morphological Segmentation of Blood Vessels in Retinal Image. *International Journal of Innovative Science, Engineering & Technology*. 2015, zv. 2, č. 7. ISSN 2348–7968. Dostupné z: http://ijiset.com/vol2/v2s7/IJISSET_V2_I6_43.pdf.
- [22] BUDAI, A., BOCK, R., MAIER, A., HORNEGGER, J. a MICHELSON, G. *High-Resolution Fundus (HRF) Image Database* [online]. 2013. Dostupné z: <https://www5.cs.fau.de/research/data/fundus-images/>.
- [23] BUDAI, A., BOCK, R., MAIER, A., HORNEGGER, J. a MICHELSON, G. Robust Vessel Segmentation in Fundus Images. *International Journal of Biomedical Imaging*. 2013, zv. 2013.
- [24] CHANG, S. H., LEIGUANG GONG, MAOQING LI, XIAOYING HU a JINGWEN YAN. Small retinal vessel extraction using modified Canny edge detection. In: *2008 International Conference on Audio, Language and Image Processing*. 2008, s. 1255–1259. DOI: 10.1109/ICALIP.2008.4590140.
- [25] CINSDIKICI, M. G. a AYDIN, D. Detection of blood vessels in ophthalmoscope images using MF/ant (matched filter/ant colony) algorithm. *Computer Methods and Programs in Biomedicine*. 2009, zv. 96, č. 2, s. 85 – 95. ISSN 0169-2607. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S0169260709001230>.
- [26] DARIA, C., VLADIMIR, M. a ANDREY, C. Multiscale Approach of Retinal Blood Vessels Segmentation Based on Vessels Segmentation with Different Scales. In: *2018 3rd Russian-Pacific Conference on Computer Technology and Applications (RPC)*. 2018, s. 1–6. DOI: 10.1109/RPC.2018.8482227.
- [27] FRANGI, A. F. et al. Multiscale vessel enhancement filtering. 1998. Dostupné z: https://www.researchgate.net/profile/WJ_Niessen/publication/2388170_Multiscale_Vessel_Enhancement_Filtering/links/0deec524580827118d000000/Multiscale-Vessel-Enhancement-Filtering.pdf.

- [28] GHADIRI, F., AKBARZADEH-T, M. a HADDADAN, S. Vessel segmentation based on Sobel operator and fuzzy reasoning. In: *2011 1st International eConference on Computer and Knowledge Engineering (ICCKE)*. 2011, s. 189–194. DOI: 10.1109/ICCKE.2011.6413349.
- [29] HASSAN, G., HASSANIEN, A. E., EL-BENDARY, N. a FAHMY, A. Blood vessel segmentation approach for extracting the vasculature on retinal fundus images using Particle Swarm Optimization. In: *2015 11th International Computer Engineering Conference (ICENCO)*. 2015, s. 290–296. DOI: 10.1109/ICENCO.2015.7416364.
- [30] HASSAN, G., EL BENDARY, N., HASSANIEN, A. E., FAHMY, A., ABULLAH M., S. et al. Retinal Blood Vessel Segmentation Approach Based on Mathematical Morphology. *Procedia Computer Science*. 2015, zv. 65, s. 612 – 622. DOI: <https://doi.org/10.1016/j.procs.2015.09.005>. ISSN 1877-0509. International Conference on Communications, management, and Information technology (ICCMIT'2015). Dostupné z: <http://www.sciencedirect.com/science/article/pii/S1877050915028355>.
- [31] HASSANPOUR, H., SAMADIANI, N. a MAHDI SALEHI, S. Using morphological transforms to enhance the contrast of medical images. *The Egyptian Journal of Radiology and Nuclear Medicine*. 2015, zv. 46, č. 2, s. 481–489. DOI: <https://doi.org/10.1016/j.ejrm.2015.01.004>. ISSN 0378-603X. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0378603X15000054>.
- [32] JELINEK, H., DEPARDIEU, C., LUCAS, C., CORNFORTH, D., HUANG, W. et al. Towards Vessel Characterisation in the Vicinity of the Optic Disc in Digital Retinal Images. *Image Vis Comput Conf*. Január 2005.
- [33] K. BALASUBRAMANIAN, N. Robust retinal blood vessel segmentation using convolutional neural network and support vector machine. *J Ambient Intell Human Comput*. 2019. DOI: 10.1007/s12652-019-01559-w. Dostupné z: <https://link.springer.com/article/10.1007/s12652-019-01559-w>.
- [34] KHATTAK, D., KHALIQ, A. a SHAHID, M. A Morphological Hessian Based Approach for Retinal Blood Vessels Segmentation and Denoising Using Region Based Otsu Thresholding. *PloS one*. Júl 2016, zv. 11. DOI: 10.1371/journal.pone.0158996.
- [35] LABIB, B. A. et al. Read the Retinal Vasculature Like a Pro. *Review of optometry*. 2017. Dostupné z: <https://www.reviewofoptometry.com/article/read-the-retinal-vasculature-like-a-pro#:~:text=The%20retina%20is%20supplied%20with,and%20the%20posterior%20ciliary%20arteries.&text=The%20first%20branch%2C%20the%20central,nasal%20to%20the%20postocular%20center>.
- [36] MACKAY, D. D. a BRUCE, B. B. Non-mydriatic fundus photography: a practical review for the neurologist. *Practical Neurology*. BMJ Publishing Group Ltd. 2016, zv. 16, č. 5, s. 343–351, [cit. 10.01.2021]. DOI: 10.1136/practneurol-2016-001443. ISSN 1474-7758. Dostupné z: <https://pn.bmj.com/content/16/5/343>.
- [37] MAISON, M., LESTARI, T. a LUTHFI, A. Retinal Blood Vessel Segmentation using Gaussian Filter. *Journal of Physics: Conference Series*. November 2019, zv. 1376, s. 012023. DOI: 10.1088/1742-6596/1376/1/012023.

- [38] MAPAYI, T., VIRIRI, S. a TAPAMO, J.-R. Retinal Vessel Segmentation Based on Difference Image and K-Means Clustering. In: 2014. Dostupné z: <http://www.prasa.org/proceedings/2014/prasa2014-10.pdf>.
- [39] MELINCAK, M., PRENTASIC, P. a LONCARIC, S. Retinal Vessel Segmentation using Deep Neural Networks. *VISAPP 2015 - 10th International Conference on Computer Vision Theory and Applications; VISIGRAPP, Proceedings*. Január 2015, zv. 1, s. 577–582. DOI: 10.5220/0005313005770582.
- [40] MEMARI, N., RAMLI, A. R., IQBAL BIN SARIPAN, M., MASHOHOR, S. a MOGHBEL, M. Retinal Blood Vessel Segmentation by Using Matched Filtering and Fuzzy C-means Clustering with Integrated Level Set Method for Diabetic Retinopathy Assessment. *Journal of Medical and Biological Engineering*. 2019, zv. 39.
- [41] MOHAMMADI SAFARZADEH, V., OSAREH, A. a SHADGAR, B. Vessel Segmentation in Retinal Images Using Multi-scale Line Operator and K-Means Clustering. *Journal of medical signals and sensors*. Apríl 2014, zv. 4, s. 122–9. DOI: 10.4103/2228-7477.130481.
- [42] OLIVEIRA, A., PEREIRA, S. a SILVA, C. A. Retinal vessel segmentation based on Fully Convolutional Neural Networks. *Expert Systems with Applications*. 2018, zv. 112, s. 229 – 242. DOI: <https://doi.org/10.1016/j.eswa.2018.06.034>. ISSN 0957-4174. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S0957417418303816>.
- [43] SAHIR, S. Canny Edge Detection Step by Step in Python — Computer Vision. *Towards Data Science*. 2019. Dostupné z: <https://towardsdatascience.com/canny-edge-detection-step-by-step-in-python-computer-vision-b49c3a2d8123>.
- [44] SAINE, P. J. a TYLER, M. E. *Ophthalmic Photography: Retinal Photography, Angiography, and Electronic Imaging*. 2. vyd. Butterworth-Heinemann Medical, 2001. ISBN 0-750-67372-9.
- [45] SALEM, S. A., SALEM, N. M. a NANDI, A. K. Segmentation of Retinal Blood Vessels Using Scale-Space Features and K-Nearest Neighbour Classifier. In: Jún 2006, sv. 2, s. II – II. DOI: 10.1109/ICASSP.2006.1660514.
- [46] SAYALI.S.KHOT, P. D. S. S. C. . A Review on Vessel Extraction of Fundus Image to Detect Diabetic Retinopathy. *Global Journal of Computer Science and Technology*. 2016, zv. 16.
- [47] SOWKA, J. W. a KABAT, A. G. Collateral Damage. *Review of optometry*. 2014. Dostupné z: <https://www.reviewofoptometry.com/article/collateral-damage>.
- [48] SREEJINI, K. a GOVINDAN, V. K. Improved multiscale matched filter for retina vessel segmentation using PSO algorithm. *Egyptian Informatics Journal*. August 2015, zv. 16. DOI: 10.1016/j.eij.2015.06.004.
- [49] TUNCER, I., KARAHAN, E. a ZENGİN, M. O. Comparment of stereo fundus photography with fundus fluorescein angiography for the incidence of cilioretinal arteries. *Spektrum der Augenheilkunde*. Apríl 2014, zv. 27, s. 245–8. DOI: 10.1007/s00717-013-0186-1.

- [50] VLACHOS, M. a DERMATAS, E. Multi-scale retinal vessel segmentation using line tracking. *Computerized Medical Imaging and Graphics*. 2010, zv. 34, č. 3, s. 213–227. DOI: <https://doi.org/10.1016/j.compmedimag.2009.09.006>. ISSN 0895-6111. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0895611109001177>.
- [51] YIN, Y., ADEL, M. a BOURENNANE, S. Retinal vessel segmentation using a probabilistic tracking method. *Pattern Recognition*. 2012, zv. 45, č. 4, s. 1235 – 1244. DOI: <https://doi.org/10.1016/j.patcog.2011.09.019>. ISSN 0031-3203. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S0031320311003980>.
- [52] ŘEHÁK, S. et al. *Oční lékařství*. 1. vyd. Avicenum / Zdravotnické nakladatelství, 1980.

Príloha A

Obsah priloženého pamäťového média

- **src**: zdrojové kódy
- **datasets**: dátové sady použité pri testovaní
- **src_latex**: zdrojové súbory dokumentácie
- **desktop app**: spustiteľný súbor desktopovej aplikácie .exe
- **xnemce06-segmentacia-ciev.pdf**: dokumentácia k bakalárskej práci